



HAL
open science

Diagnostic adaptatif à l'environnement de navigation : apport de l'apprentissage profond pour une localisation sûre et précise

Nesrine Harbaoui

► To cite this version:

Nesrine Harbaoui. Diagnostic adaptatif à l'environnement de navigation : apport de l'apprentissage profond pour une localisation sûre et précise. Apprentissage [cs.LG]. Université de Lille, 2022. Français. NNT : 2022ULILB041 . tel-04136855

HAL Id: tel-04136855

<https://theses.hal.science/tel-04136855>

Submitted on 21 Jun 2023

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

UNIVERSITÉ DE LILLE

ECOLE DOCTORALE SPI-MADIS

UMR 9189 - Unité de recherche CRISTAL

Thèse présentée par

Nesrine HARBAOUI

Soutenu le < 13/12/2022 >

En vue d'obtenir le grade universitaire de Docteur de l'Université de Lille

Discipline **Automatique et productique**

Diagnostic adaptatif à l'environnement de navigation : Apport de l'apprentissage profond pour une localisation sûre et précise

Composition du jury

Roland LENAIN	Directeur de recherche, INRAe	Rapporteur
François CHARPILLET	Directeur de recherche, Inria	Rapporteur
Louis ADOUANE	Professeur à l'Université de Technologie de Compiègne (UTC)	Président de jury
Claude DELPHA	Maître de Conférences HDR, L2S	Examinateur
Cindy CAPPELLE	Maîtresse de Conférences, UTBM	Examinatrice
Maan EL BADAOUI EL NAJJAR	Professeur à l'Université de Lille	Directeur de thèse
Nourdine AIT TMAZIRTE	Ingénieur à l'Université Gustave Eiffel	Co-encadrant de thèse

Résumé

Pour un système de transport terrestre autonome, la capacité de déterminer sa position est essentielle afin de permettre à d'autres fonctions, telles que le contrôle ou la planification de trajectoire, d'être exécutées sans danger. Ainsi, la criticité de ces fonctions génère des exigences importantes en termes de **sûreté (intégrité), de disponibilité, de justesse et de précision**¹. Pour les véhicules terrestres, la satisfaction de ces exigences est liée à divers paramètres tels que la dynamique du véhicule, les conditions météorologiques, ou encore le contexte de navigation, qui comprend à la fois l'environnement de fonctionnement et le comportement du véhicule ou de l'utilisateur. Toutes ces circonstances peuvent constituer un obstacle à la réception des signaux des systèmes mondial de positionnement par satellites GNSS (Global Navigation Satellite System) étant donné que l'environnement détermine le type et la qualité des signaux électromagnétiques disponibles pour le positionnement. Bien que de nombreuses techniques de navigation et de positionnement ont été développées, aucune n'est capable de fournir une position fiable et précise dans tous les contextes. Par conséquent, afin de déployer une fonction de localisation capable de fonctionner dans différents types de contextes, basée sur des capteurs à faible coût, principalement le GNSS et le système de navigation inertielle (INS), il est nécessaire, dès la phase de conception, de développer des stratégies permettant de résoudre à la fois l'antagonisme de certaines exigences, et l'adaptation au changement d'environnement dynamique. Dans ce contexte, cette thèse propose une couche de diagnostic qui s'adapte par des méthodes d'apprentissage profond aux changements du contexte et ajuste le compromis entre les exigences fonctionnelles. Cette couche est intégrée dans un formalisme de fusion de données tolérant aux fautes par l'intermédiaire d'une divergence informationnelle, l' α -Rényi Divergence, connue par sa généralisation d'autres divergences notamment la divergence de Kullback-Leibler, Bhattacharyya distance, Dans l'optique de détecter et isoler les défauts des capteurs, cette divergence basée sur la génération des résidus, nous offre la solution de sélectionner le résidu adéquat à chaque situation par la fixation de la valeur du paramètre α par l'apport des technologies d'intelligence artificielle afin d'augmenter la détectabilité des défauts. En vue d'augmenter la disponibilité du système tout en gardant un niveau acceptable de sûreté de fonctionnement, un seuil adapté au contexte qui ajuste le compromis entre la probabilité de fausse alarme et la probabilité de détection manquée est proposée. Pour tester et valider les approches proposées deux sortes de données ont été fournies ; réelles par la plateforme PRETIL du laboratoire CRISAL et simulées/émulées par le logiciel Stella NGC dans la cadre du projet ANR LOCSP No 2019-CE22-0011.

1. Les définitions des termes sont données dans la section 1.1

Abstract

For an autonomous terrestrial transport system, the ability to determine its position is essential in order to allow other functions, such as control or perception, to be safely controlled or perceived. Thus, the criticality of these functions generates important requirements in terms of **safety (integrity), availability, accuracy and precision**². For land vehicles, meeting these requirements is related to various parameters such as vehicle dynamics, weather conditions, or the navigation context, which includes both the operational environment and the behavior of the host vehicle or user. All of these circumstances can be an obstacle to the reception of Global Navigation Satellite System (GNSS) signals since the environment determines the type and quality of electromagnetic signals available for positioning. Although many navigation and positioning techniques have been developed, none is capable of providing a reliable and accurate position in all contexts. Therefore, in order to deploy a localization function capable of operating in different contexts, based on low cost sensors, mainly GNSS and Inertial Navigation system (INS), it is necessary, from the design phase, to develop strategies that solve both the antagonism of certain requirements and the adaptation to changing environment/dynamics. In this context, this thesis proposes a diagnostic layer that adapts by deep learning methods to changes in the context and adjusts the trade-off between functional requirements. This layer is integrated in a fault-tolerant data fusion framework through an informational divergence, the α -Rényi divergence, known by its generalization of other divergences such as the *Kullback-Leibler divergence*, the *Bhattacharyya distance*. In order to detect and isolate the divergence faults based on the generation of residuals, we offer the solution of selecting the appropriate residual for each situation by fixing the value of the parameter α using artificial intelligence technologies in order to increase the detectability of the faults. In order to increase the availability of the system while maintaining an acceptable level of operational safety, a context-sensitive threshold that adjusts the trade-off between the probability of false alarm and the probability of missed detection is proposed. To test and validate the proposed approaches, two types of data have been provided; real by the PRETIL platform of the CRISAL laboratory and simulated by the Stella NGC simulator as a part of the ANR LOCSP No 2019-CE22-0011 project.

2. The definitions of the terms are given in the section 1.1

Remerciements

Je tiens tout particulièrement à remercier mon directeur de thèse, Maan EL BADAOUI EL NAJJAR, Professeur à l'Université de Lille. Il a été le premier à croire en mes capacités et à me donner une chance de les exprimer et les développer. Il m'a permis de découvrir le monde la recherche.

Je remercie mon encadrant, Nourdine AIT TMAZIRTE, ingénieur de recherche à l'Université Gustave Eiffel pour son soutien et ses nombreux conseils pertinents et constructifs qui m'ont guidé tout au long de cette thèse. Ainsi que ses fréquents encouragements ce qui m'a permis d'accomplir un travail rigoureux.

Je tiens ensuite à remercier les rapporteurs de ma thèse Roland LENAIN et François CHARPILLET pour le temps qu'ils ont consacré à relire le manuscrit de thèse. Je voudrais aussi remercier tous les autres membres du jury Claude DELPHA, Lounis ADOUANE, Cindy CAPPELLE pour l'intérêt porté à ma thèse et les questions pertinentes qu'ils ont posées.

Je voudrais aussi remercier les ingénieurs de recherche et tous ceux qui m'ont aidé lors de mes expérimentations comme Gérard DHERBOMEZ, Elwan HERY, Maxime DUQUESNE et Gauthier DE SMET.

Je souhaite finalement remercier ma famille et mes amis pour leur encouragement et soutien tout au long de cette thèse.

Table des matières

Résumé	ii
Remerciements	iv
Table des matières	vii
Table des figures	x
Liste des tableaux	xi
Liste des abréviations	xii
1 Introduction	1
1.1 La localisation pour les véhicules autonomes	3
1.2 Contexte de travail et problématique	6
1.3 Contributions	8
1.4 Liste de publications	10
1.5 Organisation du manuscrit	11
2 État de l’art	14
2.1 Introduction	14
2.2 Les capteurs existants pour la localisation	15
2.2.1 Les systèmes GNSS :	15
2.2.2 Les capteurs proprioceptifs :	20
2.2.3 Les capteurs extéroceptifs	21
2.3 Fusion multi-capteurs	24
2.4 Complémentarité et techniques de fusion de données	26
2.4.1 Architectures de couplage des mesures GNSS et INS	28
2.4.2 Couplage lâche	28
2.4.3 Couplage serré	29
2.4.4 Couplage ultra-serré	30
2.5 Les techniques existantes d’estimation de position d’un véhicule	30

2.5.1	Les méthodes probabilistes	32
2.6	Les méthodes d'apprentissage profond et leur rôle dans la fonction de localisation	36
2.6.1	L'apprentissage automatique et l'apprentissage profond	36
2.6.2	La fusion de données par des réseaux neuronaux profonds	38
2.7	Les méthodes de Diagnostic	39
2.7.1	Diagnostic : Concepts de base et définitions	40
2.7.2	Génération des résidus par des méthodes basées sur des modèles	44
2.7.3	Génération des résidus par des méthodes basées sur les données	51
2.7.4	Les méthodes d'évaluation des résidus et prise de décision	57
2.7.5	Les méthodes d'isolation de défauts	63
2.8	Conclusion	65
3	Apprentissage profond pour la paramétrisation des résidus informationnels et seuillage d'une méthode de diagnostic adaptative : une solution au paradoxe des KPIs	66
3.1	Introduction	66
3.2	Formalisme informationnel : Fusion tolérante aux fautes adaptative au contexte pour un véhicule autonome	68
3.3	Fusion multi-capteurs : GNSS/INS/odomètre	70
3.3.1	Estimation de la position du véhicule par NIF	71
3.4	Une couche de diagnostic adaptative au contexte de navigation par apprentissage	74
3.4.1	Un résidu paramétrique basé sur la divergence de Rényi	74
3.4.2	Adaptativité d'une couche de diagnostic à l'environnement	76
3.4.3	Quelques méthodes utilisées pour la localisation dans un environnement complexe	78
3.5	La stratégie proposée	79
3.5.1	La sélection du paramètre α	80
3.6	Adaptation de la décision en fonction du contexte	84
3.6.1	Méthode de seuillage basée sur une fonction d'optimisation informationnelle le critère de Rényi Rc_α	84
3.6.2	L'estimation de P_0 et son intégration dans l'algorithme FDI	87
3.7	Conclusion	88
4	Validation de l'approche proposée : entre données réelles et jumeau numérique vers une symbiose/convergence nécessaire	90
4.1	Introduction	90
4.2	Mise en place expérimentale	91
4.2.1	Équipements techniques	91
4.2.2	Les trajectoires réelles	92

4.3	Le jumeau numérique : Vers des outils numériques fidèles pour une validation accélérée de l'approche développée	93
4.4	Stella NGC	97
4.5	Développement et résultats du concept d'adaptativité par apprentissage	98
4.5.1	La collection des données	99
4.5.2	Identification des entrées du réseau de neurones	102
4.5.3	Le clustering des données par caractéristiques	104
4.5.4	La labellisation du paramètre α	106
4.5.5	Analyse des résultats	107
4.5.6	Résultats d'une décision adaptée au contexte	114
4.6	Conclusion	123
5	Conclusion	125
5.1	Conclusion	125
5.2	Perspectives	127
	Annexes	149
A	Les méthodes d'apprentissage	150
A.1	L'apprentissage supervisé	150
A.2	L'apprentissage non-supervisé	151
A.3	L'apprentissage par renforcement	152
B	Les repères de références	153
B.1	Repère ECI	153
B.2	Repère ECEF	154
B.3	Repère de navigation	154
B.4	Repère du véhicule	155

Table des figures

1.1	La mobilité du futur	1
1.2	Les fonctions principales d'un véhicule autonome	3
1.3	Le plan du manuscrit	11
2.1	(a) Principe du système de positionnement par satellites, (b) ses limitations	20
2.2	Différence entre ISA, IMU et INS, adaptée de [161]	22
2.3	Schéma de la plateforme « stable » et de la plateforme « strapdown » ([137])	22
2.4	mode de fonctionnement du LIDAR au niveau aérien et terrestre	22
2.5	Complémentarité entre les capteurs et l'intérêt de la fusion de données	26
2.6	Schéma fonctionnel du couplage lâche INS/GNSS, adaptée de [143]	28
2.7	Schéma fonctionnel du couplage serré INS/GNSS, adaptée de [143]	29
2.8	Schéma fonctionnel du couplage ultra-serré INS/GNSS, adaptée de [143]	31
2.9	Les méthodes classiques utilisées pour la fusion des données, adaptée de [26]	32
2.10	Les méthodes d'apprentissage automatique, adaptée de [50]	38
2.11	Evolution temporelle des défauts : a) Défaut brusque ou soudain b) Défaut intermittent c) Défaut naissant	42
2.12	Approche analytique et matérielle, adaptée de [52]	43
2.13	Schéma des approches de détection des défauts basées sur les modèles	44
2.14	Schéma de l'approche basée sur l'espace de parité, adaptée de [52]	46
2.15	Schéma de l'approche basée sur un observateur : Filtre de Kalman, adaptée de [52]	46
2.16	Schéma de l'approche basée sur l'estimation des paramètres, adaptée de [52]	50
2.17	Schéma des approches de détection des défauts basées sur les données	53
2.18	Schéma du principe d'évaluation des résidus	58
2.19	Modélisation des probabilités de fausse alarme et des détection manquées	59
2.20	Choix du seuil de détection par courbe ROC	61
2.21	Architecture UIO pour l'isolation de défauts	64
3.1	Une architecture globale du concept d'adaptativité par apprentissage	67

3.2	L'architecture de la fusion tolérante aux défauts adaptative au contexte par apprentissage	69
3.3	Principe de la méthode de correspondance d'ombre ' <i>Shadow matching</i> ' [68] .	79
3.4	Illustration de l'approche de paramétrisation de résidu α -RD par une fonction sigmoïd	81
3.5	Illustration de l'approche de paramétrisation de résidu α -RD par une méthode d'apprentissage dans l'algorithme de détection de défauts	82
3.6	Illustration d'intégration de la valeur estimé de P_0 par un réseau de neurones profond dans l'algorithme de détection de défauts	87
4.1	Véhicule de test équipé du matériel	92
4.2	Schéma des équipements présents dans le véhicule de test pour l'enregistrement des données réelles	93
4.3	Vue satellitaire des trajectoires de références	95
4.4	Le jumeau numérique pour la génération et l'enregistrement des données simulées GNSS	96
4.5	Le principe de fonctionnement de Stella NGC en boucle fermée	98
4.6	Illustration de la partie expérimentale de l'approche proposée	99
4.7	Masquage satellitaire des signaux GNSS pour la trajectoire T4 à l'aide d'OpenStreetMap	101
4.8	(a) Un scénario nominal (sans défaut) de la trajectoire T4 , (b), (c) et (d) les scénarios avec défauts	101
4.9	Résultat de l'algorithme de k-means pour le partitionnement des données : (a) Coefficient de silhouette en fonction des clusters étiquetés (b) Coefficient de silhouette en fonction du nombre de clusters sélectionnés k	105
4.10	Les fonctions de densité de probabilité des résidus α -RD dans les cas « sans » et « avec » défaut pour chaque cluster pour différentes valeurs d' α	107
4.11	Le processus d'apprentissage du paramètre α	108
4.12	Architecture du réseau de neurones proposée « le perceptron multicouche » .	110
4.13	Choix de nombre de couches de neurones basé sur les métriques d'erreurs . . .	110
4.14	(a) Résultats de l'estimation du paramètre α par le réseau de neurones proposée, (b) résultats de l'évaluation du modèle d'apprentissage par une métrique d'erreur (l'erreur absolue moyenne)	111
4.15	Résidus avant l'intégration de l'approche de FDI	112
4.16	Résidus avant et après l'intégration de l'approche de FDI	112
4.17	Trajectoire avec et sans l'intégration de l'approche de FDI	113
4.18	Les résidus α -RD Partiels de chaque satellites pour la trajectoire entière . . .	113
4.19	Les élévations des satellites durant toute la trajectoire	114

4.20	Résultats de la comparaison de l'approche proposé avec la divergence de Kullback Liebler	115
4.21	Topologie du réseau de neurones de convolution proposée	117
4.22	Testing trajectories P_0 estimation performance	117
4.23	Résidus avec et sans l'intégration de l'approche de FDI	118
4.24	Les résidus α -RD Partiels de chaque satellites pour la trajectoire entière . . .	118
4.25	Les élévations des satellites durant toute la trajectoire	119
4.26	Trajectoire avec et sans l'intégration de l'approche de FDI	119
4.27	(a) Résidus avec et sans défauts basés sur un seuil utilisant MLE, (b) Résidus avec et sans défauts basés sur un seuil utilisant un RNP	120
4.28	L'impact de P_0 sur la prise de décision	120
4.29	La différence au niveau de la prise de décision en utilisant P_0 estimé avec MLE et RNP	121
4.30	L'évaluation des performances de l'approche proposée au niveau de la position	121
4.31	Performance des deux différentes méthodes d'estimation de la position; position estimée basée sur une décision utilisant le RNP (magenta) et position estimée basée sur une décision utilisant MLE (violet) dans différents contextes de navigation.	123
A.1	La différence entre un apprentissage supervisé et non-supervisé	151
B.1	Le repère inertiel ECI	153
B.2	Position du égo-véhicule e dans un système de coordonnées géodésiques (longitude latitude) ainsi que dans un repère ECEF (X_{ECEF} Y_{ECEF} Z_{ECEF}) et dans un repère ENU(X_{ENU} Y_{ENU} Z_{ENU})	155
B.3	Le repère de la voiture lié au ENU, l'axe z est orthogonal à l'ellipsoïde de référence et pointe vers le haut, l'axe des y tourne d'un angle a dans le sens inverse des aiguilles d'une montre à partir du nord et l'axe des x est orthogonal aux axes des y et des z et forme un repère de coordonnées à droite.	155

Liste des tableaux

2.1	Les différentes technologies fusionnées avec les avantages et inconvénients . . .	27
2.2	Les avantages et inconvénients des technologies GNSS et IMU.	27
2.3	Une comparaison des architectures les plus utilisées en intégration INS/GNSS	30
2.4	Les algorithmes classiques de fusion avec les caractéristiques, les avantages et inconvénients	31
2.5	Situations de décision pour un test statistique entre deux hypothèses	58
4.1	Les spécifications de quelques équipements utilisés	94
4.2	Les caractéristiques des trajectoires utilisées	95
4.3	Extrait des scénarios de défauts pour la trajectoire T4	102
4.4	Résultats de la labellisation de α basée sur le score de l'IoU pour chaque cluster	107
4.5	Evaluation des performances des deux approches par des métriques d'erreur .	122

Liste des abréviations

AE	Autoencodeurs
ADAS	Advanced Driver Assistance Systems
ANN	Artificial Neural Network
ASIL	Automotive Safety Integrity Level
BD	Bhattacharyya Distance
Bc	Critère de Bahattacharya
BDS	BeiDou Navigation Satellite System
CNN	Réseaux de neurones convolutionnels
CEG	Graphe cause-effet
CAN	Controller Area Network
DARPA	Defense Advanced Research Projects Age
DBN	Réseaux de croyance profond
DL	Deep Learning
EKF	Filtre de Kalman étendu
FD	Détection des défauts
FDI	Détection et isolation des défauts
FOG	Fiber Optic Gyroscope
FT	Tolérance aux fautes
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
GLONASS	Russian GLObal NAvigation Satellite System
GMM	Gaussian mixture models
GAFAM	Google, Apple, Facebook, Amazon et Microsoft
IA	Intelligence Artificielle
INS	Inertial Navigation System
IMU	Inertial measurement unit
ICAO	International Civil Aviation Organization
IEC	International Electrotechnical Commission
ISO	International Organization for Standardization

IF	Filtre informationnel
KLc	Critère de Kullback-Leibler
KLD	Divergence de Kullback-Leibler
KF	Filtre de Kalman
KPIs	Key Performance Indicators
LOS	Line-Of-Sight
LiDAR	Light Detection And Ranging
LSTM	Long Short-Term Memory
MEMES	Micro Electro-Mechanical Systems
MLE	Maximum Likelihood Estimation
ML	Machine Learning
MSE	erreur quadratique moyenne
MAE	erreur absolue moyenne
MLP	Perceptron multicouche
NHTSA	National Highway Traffic Safety Administratin
NLOS	Non-Line-Of-Sight
NIF	Filtre informationnel non linéaire
NIS	Normalized Innovation Square
PRN	Pseudo-Random Noise
PVT	Position, Velocity and Timing
PVA	Position, Vitesse et Attitude
PCA	Principal Component Analysis
PF	Filtre particulaire
QDE	Equations différentielles qualitative
RD	Divergence de Rényi
RLG	Ring Laser Gyroscope
RNN	Réseaux de neurones récurrents
RNP	Réseaux de neurones profond
ROS	Robot Operating System
RAIM	Receiver Autonomous Integrity Monitoring
ROC	Receiver Operating Characteristic

RMSE Root Mean Square Error
RPI Relative Performance Indicator
SDG Graphe igraphe signé
SVM Support Vector Machine
SGD Stochastic Gradient Descen
UKF Filtre de Kalman non parfumé
UIO observateurs à entrées inconnue

Chapitre 1

Introduction Générale

Chaque année, 1,35 million de personnes perdent la vie sur les routes dans le monde entier (dont 3500 en France 2019) et plus de 50 millions sont blessées. Le nombre de ces tragédies ne cesse d'augmenter [36]. Selon la National Highway Traffic Safety Administration (NHTSA ; [32]), l'erreur humaine est responsable de 93% des accidents de la route dues à plusieurs facteurs notamment la conduite trop rapide, la mauvaise évaluation du comportement des autres conducteurs, l'alcool, la distraction (par exemple le téléphone portable et autres appareils) et la fatigue.

Aujourd'hui, le véhicule autonome a commencé à trouver sa place parmi un bouquet de



FIGURE 1.1 – La mobilité du futur

services de mobilité, comme le bus à la demande, le train autonome, le tracteur autonome (figure 1.1). Certaines études pensent que la conduite autonome a le potentiel d'atténuer considérablement le nombre de morts sur la route en éliminant un bon nombre des erreurs que les conducteurs humains commettent régulièrement. Pour commencer, les véhicules autonomes ne peuvent pas être ivres, distraits ou fatigués ; ces facteurs sont impliqués dans 29%, 10% et 2,5% respectivement des accidents mortels. Ils pourraient également être plus

performants que les conducteurs humains en raison d'une meilleure exécution (par exemple, une commande plus rapide et plus précise de la direction, des freins et de l'accélération), une meilleure perception (par exemple, le problème d'angles morts) et une meilleure prise de décision (par exemple, une planification plus précise des manœuvres de conduite complexes). De plus, pour les personnes âgées qui ne sont plus en mesure de conduire, le fait de se faire conduire présente un attrait évident. Ces raisons suscitent un grand intérêt auprès de la communauté scientifique ainsi que dans l'industrie automobile qui investit depuis assez longtemps dans le développement de véhicules autonomes. Les démonstrations expérimentales réalisées par des équipes de recherche et le développement publiques comme privées ont montré la faisabilité du concept. L'un des premiers véhicules autonomes a été développé par Ernst Dickmanns dans les années 1980 [42]. Elle a ouvert la voie à de nouveaux projets de recherche, tels que PROMETHEUS, qui visaient à développer un véhicule autonome entièrement fonctionnel [209]. En 1995, le véhicule sans conducteur du laboratoire le Carnegie Mellon Navigation Laboratory (CMU NAVLAB) a réussi à parcourir 6 000 km, dont 98% de conduite autonome [13]. Une autre étape importante dans le domaine de la conduite autonome a été franchie par Defense Advanced Research Projects Agency (DARPA) en 2004 et 2005, ainsi que les concours de la DARPA Urban Challenge en 2007 [21]. Cette révolution bouleverse les acteurs du marché avec l'arrivée dans le domaine de Google, Apple, Facebook, Amazon et Microsoft (GAFAM) et d'autres entreprises à la croissance impressionnante comme Tesla, Waymo, Uber ou Mobileye [179].

Néanmoins, de nombreux défis et verrous persistent et il est indispensable de les résoudre pour envisager un déploiement massif [81]. Ces défis peuvent être classés en trois grandes catégories : les points à résoudre par les gouvernements ou les autorités réglementaires, regroupant les aspects éthiques soulevés par ces technologies, la gestion des données personnelles, les autorisations de diffusion (certifications), et les différentes stratégies et subventions pour accélérer le développement [93]. En lien direct avec ces enjeux politiques, on retrouve également des problématiques liées à la logistique, telles que la mise en place d'infrastructures permettant les communications V2X (vehicle to everything) comme le déploiement de la 5G et dans un futur proche de la 6G, la cartographie des villes etc. Et enfin les problématiques liées aux aspects opérationnels, sur lesquelles beaucoup d'efforts ont été déployés au cours des deux dernières décennies. Cependant, si le véhicule sera entièrement autonome et pourra être contrôlé à distance, il y a certains dangers que les gens doivent anticiper. Les conditions météorologiques, ou encore le contexte de navigation peuvent être considérées comme un défi dans le développement des véhicules autonomes [8]. Par exemple, les véhicules sans conducteur peuvent ne pas être en mesure de naviguer en cas de fortes pluies ou de tempêtes de neige qui peuvent obscurcir ou déformer les lignes peintes sur les routes et autoroutes. Cela peut rendre les systèmes de navigation autonomes inutiles, du moins peu fiables. Il est également possible que les véhicules autonomes posent de nouveaux et graves risques d'accident, par

exemple, le premier survenu à Williston (Dakota) le 7 mai 2016 entre une Tesla Model S en Autopilot et un camion, le deuxième à Tempe (Arizona) le 19 mars 2018 entre une piétonne et un véhicule autonome Uber. Il est clair que les véhicules autonomes présentent à la fois des avantages et des risques potentiels pour la sûreté des transports [36].

En effet, pour atteindre le niveau le plus élevé en autonomie (niveau 5) défini par International Civil Aviation Organization (ICAO) le conducteur doit être complètement remplacé, ainsi, toutes les capacités humaines nécessaires à la conduite doivent être automatisées [162]. C'est pourquoi, le véhicule doit avoir cinq fonctions principales mobilisées : la percep-

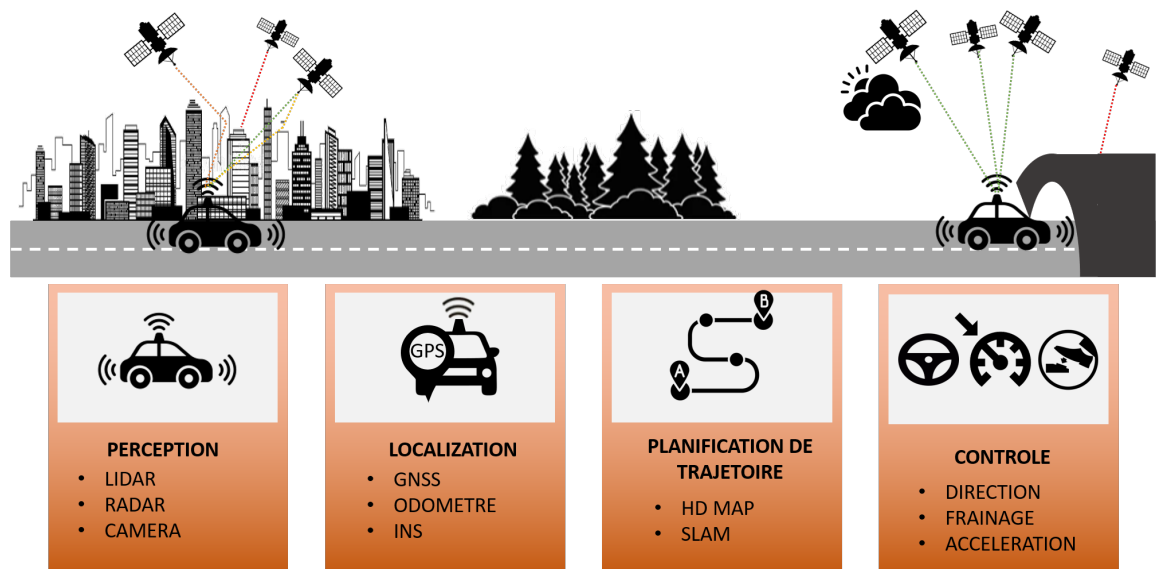


FIGURE 1.2 – Les fonctions principales d'un véhicule autonome

tion/supervision, la navigation, le contrôle et la localisation [189] (voir figure 1.2). Toutes ces fonctions sont légitimes à étudier. La fonction de localisation est particulièrement intéressante car elle constitue une entrée pour toutes les autres et elle est utilisée par des fonctions critiques, comme la fonction du contrôle [99]. Cependant, le véhicule doit avoir une multitude de capteurs qui collectent les informations utiles à la localisation et par la suite la navigation. Ces capteurs seront des dispositifs qui transforment les événements ou les changements détectés dans l'environnement en une mesure quantitative pour un traitement ultérieur.

1.1 La localisation pour les véhicules autonomes

Les véhicules autonomes ont besoin d'une connaissance précise de leur position et de leur orientation dans toutes les conditions environnementales et de circulation pour la planification de leur trajectoire, la perception et le contrôle. Pour le passage au déploiement à grande échelle, cette fonction doit répondre aux exigences opérationnelles connues en

anglais sous l'acronyme KPIs pour *Key Performance Indicators* [109].

Key Performance Indicators Dans le développement d'une application automobile, la sûreté est une exigence fondamentale. La norme ISO (*International Organization for Standardization*) 26262 a proposé la définition suivante [102] :

La sûreté (safety) : est l'absence de risque déraisonnable dû à des dangers provoqués par un fonctionnement anormal du système. Ces dangers sont ensuite classés en fonction du cadre ASIL (Automotive Safety Integrity Level), permettant de définir les exigences de sûreté.

La sûreté est un paradigme qui englobe certains des KPIs tel que l'intégrité, la fiabilité, la disponibilité et la maintenabilité. En général, ces termes portent à confusion en raison de leur interconnexion. L'ICAO [118] a proposé les définitions suivantes :

- **La fiabilité** : c'est la capacité des systèmes à se comporter de la manière prévue, dans un contexte donné, pendant une période de temps donnée et indépendamment des défauts internes ou externes du système.
- **L'intégrité** : est la capacité d'un système à fonctionner correctement selon la spécification originale du système dans une variété de conditions conflictuelles. Elle comprend la capacité d'un système à fournir des avertissements opportuns à l'utilisateur (alertes) en cas de détection de fautes pendant son propre fonctionnement.
- **La disponibilité** : elle est définie comme le pourcentage de temps pendant lequel les services du système sont utilisables par le navigateur.
- **La maintenabilité** : aptitude à effectuer des modifications faciles et des réparations peu coûteuses d'une unité fonctionnelle conformément à la réglementation en vigueur et conformément aux exigences prescrites.
- **La continuité** : est la probabilité que les performances spécifiques du système (tel que la précision et l'intégrité) seront maintenues pendant une période de fonctionnement. Elle indique principalement le fonctionnement fiable du système, en présumant que le système était disponible au début de cette période d'opération.

Et selon les normes standards ISO 3534-2 [82] :

- **La justesse** est définie comme l'exactitude de la mesure par rapport à valeur réelle.
- **La fidélité** est le degré auquel des mesures répétées dans des conditions identiques donnent les mêmes résultats, indépendamment de la justesse de l'une de ces mesures.
- **La robustesse** est la capacité d'un système à répondre d'une manière appropriée à des conditions aberrantes tel que les conditions environnementales.

- **L'exactitude** l'exactitude d'une mesure estimée est définie comme une combinaison de la fidélité et de la justesse.

Les expérimentations déclarées pour tester des véhicule autonomes en France par exemple n'ont lieu que sur site fermé ou voie dédiée. Pour passer sur la voie publique au milieu de la circulation, il faut assurer un niveau de sûreté maximal presque de 100%, ce qui représente la seule garantie d'une acceptabilité massive. En fait, les constructeurs automobiles et études scientifiques visent au mieux le 10^{-9} moins d'un défaut pour un milliard de *km* parcourus. Un autre accord de fiabilité pour le véhicule autonome est fixé à 10^{-8} /heure, c'est-à-dire que la probabilité d'occurrence d'un défaut grave doit être inférieur à 10^{-8} pour une heure donnée, un taux 10 fois inférieur à la moyenne européenne de régulation des produits défectueux [36]. D'autre part, le défi en termes de précision et de fiabilité de la position est important. Les véhicules autonomes nécessitent un positionnement décimétrique pour les autoroutes et près du centimètre pour les rues résidentielles. Ces exigences répondent à un seul objectif : garantir que le véhicule sait qu'il se trouve dans sa voie de circulation [151].

Durant ces dernières années, plusieurs approches et technologies visant à améliorer chacune de ces exigences opérationnelles de la brique de localisation ont été développées. Pour assurer la précision et la disponibilité, des stratégies de fusion de données multi-capteurs ont été employées ; ces processus qui consistent à combiner les observations d'un certain nombre de capteurs différents pour fournir une description fiable et complète d'un environnement ou d'un événement particulier [45]. En général, les capteurs sont classés en trois catégories en fonction de leur principe de fonctionnement [212] : les capteurs de positionnement par satellites (récepteurs GNSS), les capteurs proprioceptifs, ou capteurs d'état interne, capturent l'état dynamique et mesurent les valeurs internes d'un système dynamique, par exemple, la force, la vitesse angulaire, la charge des roues, la tension de la batterie, etc. Parmi les capteurs proprioceptifs, on peut citer les unités de mesure d'inertie (IMU), les encodeurs, les capteurs inertiels (gyroscopes et magnétomètres). En revanche, les capteurs extéroceptifs, ou capteurs d'état externes, détectent et collectent des informations telles que des mesures de distance ou l'intensité lumineuse de l'environnement du système. Les caméras, la détection et la télémétrie par radio (radar), la détection et la télémétrie par la lumière (LiDAR) et les capteurs à ultrasons sont des exemples de capteurs extéroceptifs [192], [39]. En outre, les capteurs peuvent être soit des capteurs passifs, soit des capteurs actifs. Les capteurs passifs reçoivent l'énergie émise par l'environnement pour produire des sorties, par exemple, les caméras de vision. À l'inverse, les capteurs actifs émettent de l'énergie dans l'environnement et mesurent la "réaction" de l'environnement à cette énergie pour produire des résultats, comme c'est le cas des capteurs LiDAR et radar [207]. Tous ces capteurs présentent des avantages et des inconvénients, ainsi que des limites dans différentes conditions environnementales. Par exemple, les systèmes GNSS seuls sont incapables de fournir une localisation fiable malgré qu'ils proposent un positionnement qualifié de juste et qu'ils constituent une des sources

de mesures les plus répandues pour la localisation absolue d'un véhicule en milieu ouvert. En revanche, dans les zones urbaines, tunnels, forêts ou lac les signaux GNSS peuvent être bloqués ou masqués par plusieurs phénomènes, ce qui peut affecter potentiellement la sûreté du système [66]. D'où la nécessité d'intégration de divers capteurs permettant de recueillir des informations de l'environnement d'une part, et d'améliorer la localisation d'autre part. De nombreuses études récentes ont été publiées sur le sujet de la fusion multicapteurs, certaines d'entre elles décrivent la structure architecturale et les technologies de capteurs dans les véhicules autonomes [22], [200] ou se concentrent sur les étapes de traitement comme le calibrage des capteurs, l'estimation de l'état, l'objet et le suivi [90], [26] ou détaillent les techniques utilisées pour la fusion multicapteurs, comme les approches basées sur l'apprentissage profond [50], [115]. Toutefois, dans un contexte de navigation complexe, le système peut être soumis à de multiples perturbations qui peuvent provoquer des erreurs significatives dans les mesures des capteurs ou des incertitudes notables autour de la position estimée. Ces erreurs peuvent affecter les performances du système, sa sûreté en particulier. La détection des défauts et la prise de décision peuvent être utiles pour surmonter ces problèmes. Les avantages de la détection des défauts et de la prise de décision ont été largement démontrés dans les systèmes de localisation pour plusieurs applications telles que la robotique et la navigation de véhicules.

1.2 Contexte de travail et problématique

L'élément considéré comme freinant le développement des véhicules autonomes étant d'assurer leur sûreté, les exigences qui en sont liés doivent être prises en compte dans le développement des grandes fonctions les composant. Cependant, la sûreté n'est pas l'unique objectif opérationnel que doit atteindre la fonction de localisation. En effet, il en est attendu d'assurer un certain niveau de précision, de disponibilité et de continuité en milieu urbain ou dans des zones présentant un danger pour la vie humaine. Certaines de ces exigences ont un fonctionnement que l'on pourrait qualifier d'antagoniste (assurer par exemple la sûreté étant nécessairement au détriment de la disponibilité). De plus, les choix technologiques afin d'implémenter cette fonction doivent tenir en compte du fait que cette fonction doit être capable de proposer une position à froid, sans connaissance à priori du lieu dans lequel le véhicule évolue et également d'assurer la continuité du service. Les GNSS sont une solution technologique qui permettent dans beaucoup de cas de répondre à la première exigence de positionnement à froid, mais ce système de localisation n'est disponible que par intermittence. Ils doivent donc être couplés avec un système de navigation à l'estime ainsi que d'autres capteurs proprioceptifs (l'odométrie/la gyroscopie, les unités de mesures et de calculs inertiels (IMU/INS)...), exteroceptifs (vision, Lidar...) ou d'autres sources d'information (cartographie 2D/3D ou HD). L'analyse des différentes informations fournies par ces capteurs selon le

contexte de navigation est une étape cruciale pour assurer une estimation fiable de la position, car les mesures fournies peuvent être entachées d’erreurs dues au changement brutale de contexte par exemple, ou à des contraintes environnementales citées précédemment résultant de défauts. Ces défauts peuvent avoir un impact direct sur l’intégrité et la précision du positionnement, affectant ainsi la performance du système global.

Bien que de nombreuses techniques de positionnement et de navigation aient été développées, aucune n’est capable de fournir un positionnement fiable et précis dans tous les contextes. Il est donc nécessaire de concevoir une couche de diagnostic qui détecte et prend la décision concernant ces défauts capteurs. Cette méthode doit offrir la faculté de s’adapter au contexte de navigation. Dans la littérature, différentes techniques de détection et d’isolation de défauts sont utilisées. Elles sont divisées en deux types de méthodes : les méthodes basées sur l’utilisation de modèles analytiques (filtrage bayésien récursif, relations de parité, ...), les méthodes basées sur les données (réseaux neuronaux artificiels, réseaux bayésiens, ...). Par conséquent, un aspect important à considérer est le choix de l’architecture de la couche de diagnostic pour assurer l’adaptation au contexte et garantir les meilleures performances du point de vue de la localisation et du calcul.

L’objectif de ces travaux de thèse est de proposer une méthode de localisation sûre, précise et disponible capable de détecter des défauts capteurs (principalement défauts GNSS) selon le contexte de navigation. Le but est de concevoir une approche adaptative au contexte qui détecte les défauts des capteurs et prend la décision concernant ces derniers en adoptant différentes techniques de positionnement.

Dans cette étude, le formalisme global de la localisation est abordé sous plusieurs niveaux afin de satisfaire toutes les exigences opérationnelles. Il est composé de :

1. Une couche de fusion de données multi-capteurs,
2. Une couche de détection des défauts,
3. Une couche de gestion des défauts.

La nouveauté dans ce formalisme se manifeste dans la deuxième couche par l’intégration des méthodes d’Intelligence Artificielle (IA), plus particulièrement l’apprentissage profond dans la détection des défauts et la prise de décision. Au cours de ces dernières années, ces techniques sont devenues les principales technologies à l’origine de nombreuses percées dans le développement des véhicules autonomes notamment la localisation, diagnostic et prise de décision dans la recherche ainsi que les constructeurs autonobile [77]. Par exemple, les algorithmes d’IA utilisés par les « digital native » (Waymo, Tesla, Uber) ils sont basés sur des réseaux de neurones artificiels [35], [128]. En termes de développement informatique, on change de paradigme, passant du codage algorithmique classique de plusieurs millions de lignes à l’apprentissage de réactions à des millions de scénarios de conduite étiquetées par

des conducteurs avisés. Ces applications développées ont prouvé l'efficacité de ces méthodes et leur contribution à la réduction de la plupart des erreurs humaines telles que la conduite agressive, les accidents et les collisions de la circulation, etc. Néanmoins, ces algorithmes présentent certaines limitations vu qu'ils nécessitent une quantité importante des données pour l'entraînement, et il n'y a pas que la quantité des données d'apprentissage qui intervient, mais aussi la qualité des données d'apprentissage, ce qui laisse douter de leur robustesse. Des recherches récentes ont démontrées qu'une légère perturbation de ces données (Par exemple d'empoisonnement des données), elles peuvent être mal classées par les algorithmes d'IA ce qui peut engendrer des catastrophes [187].

L'objectif de la thèse est de développer une approche de diagnostic adaptative au contexte de navigation basée sur la théorie de l'information couplée avec les méthodes d'intelligence artificielle pour une localisation fiable d'un véhicule autonome. Tout d'abord, un formalisme global de fusion de données multi-capteurs tolérant aux fautes est proposé. Dans le but de renforcer la précision du positionnement global du véhicule, nous présentons un couplage serré des données brutes de GNSS et IMU, basé sur une technique de filtrage informationnel comme estimateur d'état. Ensuite, dans l'optique d'améliorer la sûreté du système, une couche de diagnostic adaptative s'intègre dans cette base permettant de détecter et d'isoler les mesures des capteurs aberrantes. Cette couche est basée sur la génération des résidus par une métrique informationnelle. Cette métrique permet de distribuer la confiance entre un modèle mathématique en lien avec la dynamique du véhicule et les observations des capteurs influencées par leur environnement. Ce qui nous ramène à l'aspect adaptative de cette couche, où une approche basée sur les données (par les méthodes d'apprentissage profond) va renforcer une base théorique (mesure informationnelle) pour sélectionner le résidu et la décision appropriée à la situation de navigation en jugeant de la pertinence et la qualité des observations dans chaque cas étudié.

1.3 Contributions

L'objectif général de cette thèse est d'établir un formalisme adaptatif au contexte de navigation pour une localisation sûre/intègre, précise et disponible d'un véhicule autonome. Ce formalisme peut déterminer les environnements à l'aide des capteurs GNSS, IMU et odomètre. Il est basé sur une technique de fusion multi-capteurs basée sur un filtrage stochastique. Simultanément, une couche de diagnostic, basée sur un résidu informationnel combiné avec des méthodes d'apprentissage profond, est intégrée pour détecter et isoler les défauts des capteurs d'une manière fiable. Tous ces éléments constituent la base d'un système de navigation adaptatif au contexte environnemental. Pour répondre à cet objectif général, les principales contributions de cette thèse, regroupées par niveaux, sont résumées comme suit :

1. **Architecture de fusion des données multi-capteurs** Le choix des capteurs et de

l'architecture d'intégration de ces capteurs est une étape fondamentale et nécessaire au développement d'une méthode de localisation. Elle doit donc constituer un élément essentiel d'une démarche visant à atteindre des objectifs comme la précision et la disponibilité. Dans cette thèse, on propose une approche basée sur des capteurs avec un aspect fonctionnel complémentaire, l'intégration de ces derniers est basée sur la théorie de l'information, par l'utilisation du filtre d'information non linéaire. Par rapport au filtre de Kalman non linéaire, la forme informationnelle de ce filtre offre plus d'avantages en terme de calcul, temps de traitement et d'adaptativité en cas de variation de nombre d'observations dans le temps, vu que le calcul peut se réaliser d'une façon distribuée grâce à la modélisation de l'étape de mise à jour (somme des contributions).

2. **Couche de diagnostic adaptative au contexte de navigation basée sur des méthodes d'apprentissage** Dans la continuité des travaux proposés dans [129], la couche de diagnostic est basée sur la génération des résidus par la divergence informationnelle α -Rényi connue comme une généralisation d'une infinité de divergences, grâce au paramètre α . Dans cette thèse, on propose une approche adaptative au contexte par l'intégration des méthodes d'apprentissage à deux niveaux de la couche de diagnostic. Vu qu'on utilise les systèmes GNSS et qu'ils dépendent fortement du contexte environnemental dans lequel le véhicule évolue, cela souligne l'importance et la nécessité d'une couche de diagnostic qui s'adapte au contexte. Pour assurer le compromis approprié entre les contraintes opérationnelles selon la situation de navigation, un résidu paramétré appelé α -RD est conçu par l'analyse des mesures brutes GNSS et des informations venant du filtrage de la partie de fusion. En vue de maximiser la précision et la disponibilité du système, une approche basée sur l'apprentissage est développée pour : surveiller la qualité des mesures reçues, et estimer au mieux les probabilités (la probabilité d'absence de défaut(s) P_0 et la probabilité de présence de défaut(s) P_1) sans une connaissance a priori. Par conséquent, l'adaptation du seuil de détection en fonction du contexte environnemental pour améliorer la performance globale du système est primordiale.

→ **La génération des Résidus informationnels paramétrés par apprentissage** Dans cette thèse, le paramètre α représente un degré de liberté supplémentaire pour la couche de diagnostic. Il permet de choisir parmi un nombre infini de résidus celui qui maximise la détectabilité des défauts, en particulier les défauts soudains. L'objectif est la sélection de la valeur appropriée du paramètre α qui s'adapte avec le contexte de navigation d'un véhicule. Cette sélection est basée sur un processus d'apprentissage qui prend en compte plusieurs caractéristiques, parmi lesquelles les incertitudes entourant les modèles d'évolution et d'observation. Cette approche est divisée en deux parties : le prétraitement des données et

la paramétrisation des résidus.

- **Prise de décision par une fonction d'optimisation informationnelle améliorée par un réseau de neurones profond** Lorsque l'accent est mis sur la précision, seules les performances en termes d'erreur de position sont importantes. Pour les études visant à maximiser la disponibilité, le seuil de détection est fixé en tenant compte d'une probabilité minimale de fausse alarme (P_{fa}). Et pour les études visant à maximiser la sûreté, c'est la probabilité de détection manquée (P_{mD}), et donc la probabilité de détection (P_D), qui importe. Mais la nécessité d'atteindre tous les objectifs impose d'établir une politique de seuillage tenant compte de tous les critères. Dans cette étude, on propose une politique qui tend à trouver le bon compromis entre P_{fa} et P_{mD} par l'intégration des réseaux de neurones profonds dans une fonction d'optimisation basée sur la théorie d'information.
- **Test et validation de l'approche proposée par des données réelles et simulées/émulées** L'approche proposée est testée et validée à l'aide des données brutes GNSS, IMU et odomètre réelles en utilisant différentes trajectoires de test. Les données GNSS brutes sont générées à partir d'un véhicule robotisé et d'un simulateur/émulateur GNSS.

1.4 Liste de publications

Revue Internationale :

- N. Harbaoui, K. Makkawi, N. Aittmazirte, and M. E. El Najjar, « Context adaptive fault tolerant multi-sensor fusion : towards a fail-safe multi operational objective vehicle localization », *Journal of Intelligent & Robotic Systems* : à paraître.

Conférences internationales :

- N. Harbaoui, N. Aittmazirte and M. E. El Najjar, « Environment Adaptive Diagnostic Framework For Safe Localization of Autonomous Vehicles ». MFI 2022, September 2022 : à paraître.
- N. Harbaoui, N. Aittmazirte, K. Makkawi and M. E. El Najjar, « Navigation Context Adaptive Fault Detection and Exclusion Strategy based On Deep Learning & Information Theory : Application To a GNSS/IMU integration ». InION GNSS+ 2021, September 2021, DOI: 10.33012/2021.17970.

- N.Harbaoui, K. Makkawi, N. Aittmazirte, and M. E. El Najjar, « An α -Rényi Divergence Sigmoid Parametrization For A Multi-Objectives And Context-Adaptive Fault Tolerant Localization », 2021 IEEE 24rd International Conference on Information Fusion (FUSION), Pretoria, South Africa, virtual conference, Novembre 1–4, 2021, HAL ID: hal-03427180.
- K. Makkawi, N.Harbaoui, N. Aittmazirte, and M. E. El Najjar, « α -Rényi based framework for a Robust and Fault-Tolerant Localization», 2021 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI), Karlsruhe, Germany, virtual conference, September 23–25, 2021, HAL ID : hal-03427178.

1.5 Organisation du manuscrit

En vue de répondre à l'objectif principal, une localisation adaptative au contexte de navigation par des méthodes d'apprentissage. Cette méthode consiste à garantir l'intégrité d'une position d'un véhicule autonome tout en augmentant la disponibilité du système selon le contexte de navigation. Le principal objectif de cette thèse est de développer une couche

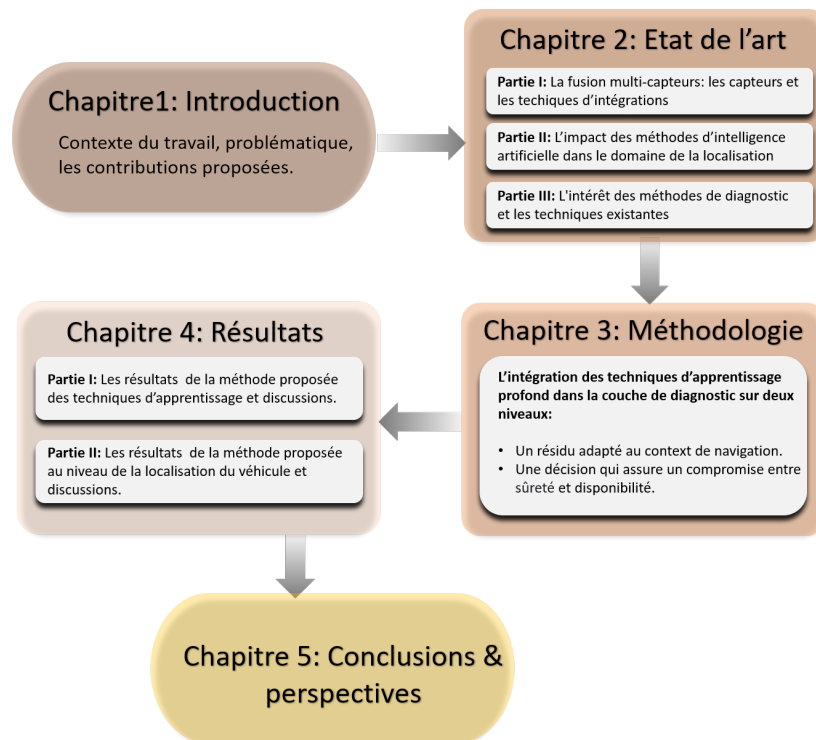


FIGURE 1.3 – Le plan du manuscrit

de diagnostic qui vise à établir un compromis entre les exigences opérationnelles définies par les normes standards pour améliorer la position du véhicule, ce manuscrit est organisé

en 5 chapitres (voir figure 1.3). Après une introduction générale, le **chapitre 2** présente 3 parties :

- *Partie I* : introduit les technologies utilisées pour la localisation d'un véhicule autonome, leur spécificités plus particulièrement les systèmes GNSS. Ces systèmes feront l'objet d'une description détaillée dans ce chapitre, en raison de la place prépondérante qu'ils occupent dans la localisation automobile. Par la suite, la complémentarité des capteurs et les méthodes de fusion multi-capteurs sont présentées.
- *Partie II* : met l'accent sur le rôle des méthodes d'apprentissage dans le développement des véhicules autonomes, plus précisément la brique de localisation.
- *Partie III* : présente les méthodes de diagnostic : les méthodes basées sur les modèles, principalement les méthodes de génération de résidus basée sur les observateurs ou les filtres. Enfin une comparaison des méthodes basées sur les modèles et des méthodes basées sur les données (les méthodes de diagnostic par apprentissage) est proposée.

Le **chapitre 3** aborde l'approche adoptée dans ce travail. Dans la première partie, on présente le formalisme général, la méthode de couplage GNSS avec le système inertiel. En deuxième partie, l'approche adaptative d'une couche de diagnostic est développée pour la localisation incluant une étape de détection et d'exclusion des défauts satellites, selon le contexte de navigation du véhicule. Dans ce cadre, on propose les bases théoriques et mathématiques relatives à l'algorithme de détection et d'exclusion de défauts appliqués au GNSS : approche informationnel. En deuxième partie, on présente l'intérêt du choix et la valeur ajoutée de l'intégration des méthodes d'apprentissage dans notre approche informationnel de diagnostic. Cette intégration est développée sur deux niveaux :

- *La génération de résidu* est basée sur la divergence de α -Rényi. Ce résidu est paramétré grâce à son paramètre α . Le choix de la valeur de ce paramètre est fournie par un réseau de neurones profond selon le contexte de navigation.
- *La prise de décision* est basée sur un seuillage optimisé basée sur un critère informationnel de la divergence de α -Rényi. Principalement, cet critère est dépendant de la valeur de la probabilité d'absence de défaut(s) P_0 . Cette valeur est sélectionnée par un réseau de neurones profond pour assurer un compromis entre la sûreté et la disponibilité dans un contexte environnemental.

Le **chapitre 4** propose l'application du formalisme globale dans le domaine de la robotique, sur un véhicule robotisé, ces résultats seront présentés sur deux parties :

- *La partie I* : montre les résultats expérimentaux obtenus des algorithmes d'apprentissage sur des données réelles enregistrées par un récepteur GNSS et par le simulateur/émulateur Stella NGC.

- *La partie II* : présente l'impact des résultats d'apprentissage sur l'algorithme de détection et d'isolation des défauts. Par la suite, les résultats au niveau de la position du véhicule sont présentés et discutés.

Finalement, une conclusion générale et les perspectives sont proposées dans le **chapitre 5**.

Chapitre 2

État de l'art

Ce chapitre traite la fusion de données tolérante aux fautes. Dans un premier temps, les différentes technologies pour la localisation d'un véhicule sont présentées par catégories. Par la suite, les architectures de fusion multi-capteurs sont proposées brièvement : Couplage lâche, serré et ultra-serré. Puis les techniques d'intégration sont présentées : probabilistes, statistiques, les techniques basées sur les connaissances, la preuve et l'analyse d'intervalle. Dans un second temps, la prépondérance des défauts comme cause d'erreur dans la localisation exige la présentation, d'un cadre théorique de la détection et de l'isolation de défauts. Ce cadre est détaillé en décrivant les méthodes de diagnostic classiques et l'apport des méthodes d'apprentissage dans la détection des défauts capteurs.

2.1 Introduction

Lors de la dernière décennie, les progrès réalisés dans les domaines de la robotique et des systèmes de transport intelligents ITS (*Intelligent Transportation Systems*), ont contribué au développement des véhicules autonomes. L'une des exigences fondamentales de tout véhicule autonome est qu'il ait la capacité de se localiser en toute sécurité et de prendre des décisions intelligentes selon son contexte de navigation en temps réel. En effet, les capteurs sont indispensables pour assurer un fonctionnement sûr et autonome de ces systèmes, dans des environnements inconnus et dynamiques, où il est difficile d'avoir des informations "*a priori*". Ainsi, le nombre et les types de technologies intégrées dans les véhicules sont en croissance exponentielle, pour fournir des informations redondantes et complémentaires, et atteindre à long terme le niveau d'autonomie et de sûreté exigé par les normes standards ISO et IEC (*International Electrotechnical Commission*).

Les systèmes ADAS (*Advanced Driver Assistance Systems*) commercialisés sur le marché font actuellement usage d'un certain nombre de capteurs pour obtenir une quantité importante

d'informations sur la localisation et contexte de navigation du véhicule. Toutefois, ils ne permettent pas jusqu'à présent aux véhicules d'effectuer des tâches entièrement autonomes. Certains prototypes des premiers véhicules autonomes ont déjà été proposés. Cependant, ces solutions sont généralement complexes, coûteuses, et nécessitent souvent des ressources informatiques importantes pour être intégrées dans les véhicules commerciales. Par ailleurs, des recherches approfondies ont été menées afin de comprendre quel type de capteur est le plus adapté à une application particulière, comment il peut être implémenter dans un système pour fonctionner de manière efficace, et comment il peut être combiner avec d'autres capteurs pour créer un système de localisation plus intelligent. Pour répondre à ces questions, ce chapitre présente un état de l'art sur plusieurs niveaux :

- Les différentes technologies utilisées, leurs avantages, et limitations.
- Les techniques de fusion multi-capteurs.
- L'apport des méthodes d'apprentissage profond dans la localisation d'un véhicule autonome.
- Les méthodes de diagnostic pour améliorer les performances de ces capteurs et aboutir à une localisation sûre et fiable d'un véhicule autonome.

2.2 Les capteurs existants pour la localisation

Il est évident qu'un véhicule autonome ne peut se positionner et connaître son environnement que par l'intermédiaire de ses capteurs. Ces capteurs doivent être capables de créer une vue pertinente du contexte où le véhicule évolue afin qu'il puisse se localiser et prendre les bonnes décisions. Cette section présente les capteurs les plus couramment utilisés pour la localisation des véhicules autonomes, plus précisément pour estimer l'état, tels que la position et la direction.

2.2.1 Les systèmes GNSS :

En raison de leur capacité à fournir une position n'importe où sur la Terre sans connaissance à priori, de leur précision relative, de leurs bonnes performances et des différents domaines d'utilisation, la technologie la plus utilisée en matière de navigation et de positionnement en extérieur reste le système global de positionnement par satellite (GNSS). GNSS est le terme générique qui englobe des constellations des satellites gravitant à environ vingt mille kilomètres de la surface de la planète. Ces satellites émettent des signaux depuis l'espace, permettant de les localiser sur leur orbite et d'estimer la distance entre le satellite et

le récepteur [155]. Ainsi, on distingue deux méthodes de positionnement par satellites. La première méthode est basée sur un positionnement absolu. Elle utilise le concept de trilatération (voir figure 2.1.a)), à partir des informations émises par les satellites visibles, elle fournit une position à tout instant. Quant à la deuxième méthode, elle consiste en un positionnement en différentiel (*ou DGNS : Differential GNSS*) qui utilise stations de base réparties au sol. La position de chacune d'entre elles doit être connue avec précision. Ces stations transmettent aux récepteurs les corrections des erreurs de trilatération pour améliorer la précision du positionnement.

Le principe de fonctionnement Le positionnement par satellites est basé sur le principe de la trilatération de signaux électromagnétiques émis par les satellites. Le signal GNSS est constitué d'une porteuse, un message contenant les données de navigation appelé message de navigation et une séquence unique de code pseudo aléatoires PRN (*Pseudo-Random Noise*). Une réplique de la séquence du code du satellite est générée par le récepteur. Le temps de propagation correspond à la différence de temps entre deux instants : « code généré » et « code reçu » au niveau du récepteur. Ce temps est multiplié par la vitesse de la lumière dans le vide pour obtenir la distance émetteur-récepteur, appelée pseudo-distance. En effet, en considérant que l'horloge du satellite et celle du récepteur ne sont pas parfaitement synchronisées [201]. Cependant, les mesures de distance entre le récepteur et les satellites peuvent être contaminées par une erreur de synchronisation appelée « biais d'horloge ». De plus, les signaux GNSS peuvent également être contaminés par différentes sources d'erreur, affectant ainsi le temps de propagation du signal (voir figure 2.1.b)). C'est pour ces raisons, la pseudo-distance est définie comme la distance mesurée séparant le récepteur d'un satellite, en incluant les différentes erreurs associées tel que :

$$\rho = d + c.\delta t + \eta_\rho \quad (2.1)$$

Où :

c : la vitesse de la lumière, $c = 2.99792458 \times 10^8$

ρ : mesure de pseudo-distance

δt : biais d'horloge du récepteur

η_ρ : erreurs supplémentaires affectant la mesure de pseudo-distance

d : la mesure de distance entre le récepteur et un satellite

Avec :

$$d = \sqrt{(x - x_{si})^2 + (y - y_{si})^2 + (z - z_{si})^2} \quad (2.2)$$

Où :

x, y, z : représentent la position du récepteur

x_{si}, y_{si}, z_{si} : la position du $i^{\text{ème}}$ satellite au moment de l'émission du signal

Théoriquement, il est nécessaire d'avoir trois satellites afin d'obtenir trois pseudo-distances à partir des coordonnées de chaque satellite. Chaque satellite est identifié à partir du code PRN qu'il envoie. Ainsi, le récepteur peut obtenir les coordonnées des trois satellites à l'instant de l'émission du signal. La position du récepteur est obtenue comme une intersection de trois sphères. Chaque sphère a pour centre un satellite et pour rayon la pseudo-distance qui sépare le satellite du récepteur. En pratique, un minimum de quatre satellites est nécessaire pour résoudre la désynchronisation entre l'horloge du récepteur et les horloges atomiques embarquées dans les satellites.

Constellations Il existe de nombreuses constellations de GNSS. Le système GPS (*Global Positioning System*) a été développé par le département de la défense des Etats Unis à partir de 1978. Il a été conçu à l'origine pour des précisions de positionnement de l'ordre du mètre [141]. Cependant, depuis sa première déclaration comme un système opérationnel en 1993 [120], plusieurs développements, principalement par la communauté civile, ont contribué à atteindre une position centimétrique. Cette capacité à fournir une large gamme de justesse de positionnement dans toutes les conditions météorologiques, a permis à cette technologie de révolutionner le positionnement et la navigation modernes. Par la suite, le système russe GLONASS (*Russian GLObal NAVigation Satellite System*) est devenu totalement opérationnel en décembre 2011. Le système chinois BDS (*BeiDou Navigation Satellite System*) et le système européen Galileo sont actuellement en cours de développement, bien que le BDS a commencé un service opérationnel initial fin décembre 2011 et que Galileo a été déclaré opérationnel en décembre 2016 pour des services initiaux. D'une manière générale, une constellation GNSS comprend trois segments majeurs [96] :

Segment spatial Ce segment comprend les satellites à partir desquels les utilisateurs effectuent des mesures de distance. Les principales fonctions du segment spatial sont de :

- Générer et transmettre les signaux de code et de phase.
- Stocker et diffuser les messages de navigation téléchargés par le segment de contrôle.
- Assurer la visibilité simultanée de quatre satellites au minimum depuis n'importe quel point de la surface de la Terre à tout instant.

Pour le système GPS, le segment spatial se compose de 24 satellites, répartis sur 6 orbites inclinées de 55° sur le plan équatorial et situées à une altitude de 20,184 km avec une période de 11h58 min 2s.

Segment de contrôle L'objectif de ce segment est d'assurer un fonctionnement et une exploitation correct du système. Il est généralement composé d'un réseau d'infrastructures

au sol, telles que des stations de contrôle, des antennes au sol. Elles permettent de :

- Contrôler et de maintenir l'état de la constellation de satellites.
- Prédire l'évolution des éphémérides et de l'horloge des satellites.
- Mettre à jour les messages de navigation de tous les satellites, les informations mises à jour sont transmises à chaque satellite via les antennes au sol.

Segment utilisateur Ce segment regroupe tous les types d'équipements de réception destinés aux utilisateurs, généralement appelés "récepteurs GNSS". Les récepteurs GNSS sont capables de recevoir les signaux GNSS émis par les satellites, de déterminer les pseudo-distances (ou autres mesures), puis de fournir des solutions de position, de vitesse et de la datation de la réception ("*Position, Velocity and Timing*", *PVT*).

Les sources d'erreurs du GNSS Les mesures provenant des signaux GNSS peuvent être affectées par différentes sources d'erreur. Généralement, ces erreurs peuvent provenir soit des satellites, soit du récepteur, ou de la propagation des signaux. En outre, la géométrie des satellites est également un facteur important qui peut affecter la précision de la solution de navigation calculée par un récepteur GNSS. Dans cette partie, on présente brièvement les sources d'erreurs les plus connues dans la littérature [96, 201].

Erreur d'horloge

Les signaux émis par les satellites sont affectés par des erreurs d'horloges qui proviennent des satellites ou du récepteur. Concernant les satellites, ces erreurs sont dues généralement à l'instabilité de l'horloge des satellites, qui peut affecter la mesure de pseudo-distance calculée par le récepteur. Ces erreurs peuvent être corrigées, par les coefficients d'horloges contenus dans le message de navigation des satellites. Ils sont utilisés pour la détermination de ces erreurs. En revanche, l'erreur de l'horloge des récepteurs est plus importante et plus complexe à traiter. Généralement, l'horloge des récepteurs GPS commerciaux est une horloge peu coûteuse au quartz. Pour ces raisons, l'erreur de l'horloge des récepteurs GNSS est estimée à l'intérieur du filtre de navigation.

Erreur ionosphérique

L'une des principales sources d'erreurs dans les mesures de pseudo-distance, est la propagation des signaux GNSS à travers l'ionosphère. Elle peut provoquer des erreurs, atteignant jusqu'à 50 m pour les satellites à faible degré d'élévation et 15 m au zénith (Sauriol, 2008). Cette erreur elle se manifeste par un retard. La principale source de ces retards est l'ionisation des atomes et des molécules gazeuses par le rayonnement solaire et cosmique présent dans cette couche atmosphérique, ce qui peut entraîner des électrons libres interférant avec le signal GNSS. Cette erreur est extrêmement difficile à prédire car l'intensité de ce phénomène dépend

d'un certain nombre de variables, notamment l'heure, la saison, la position géographique et les activités solaires et géomagnétiques.

Erreur toposphérique

La couche troposphère est une couche gazeuse. Elle forme la couche basse de l'atmosphère (couche d'environ 50 km d'épaisseur) . Cette couche n'est pas un milieu dispersif pour les ondes radio, c'est-à-dire, que le délai troposphérique affectant les ondes porteuses ne change pas avec la fréquence de l'onde. Mais les conditions atmosphériques et leur variation ont une influence sur ce dernier, notamment la température, l'humidité relative et la pression atmosphérique [105]. Étant donné que cette couche est principalement constituée de gaz secs et de vapeur d'eau, elle réfracte les signaux GNSS, ce qui peut entraîner un retard de propagation qui a un impact direct sur la mesure de la pseudo-distance. De plus, l'angle d'élévation du satellite amplifie également l'amplitude du délai troposphérique.

Multipath

Les trajets multiples ou Multipath est un phénomène qui désigne la présence d'un objet réfléchissant près de l'antenne d'un récepteur GNSS qui peut provoquer une réflexion ou diffraction des signaux provenant des satellites. Dans ce cas, l'antenne reçoit le signal original émis par le satellite en plus du signal réfléchi. Ce qui introduit des erreurs dans la détermination de la position du récepteur.

NLOS : Non-Line of Sight

Le NLOS est un phénomène qui se produit dans le cas où le signal direct LOS (*Line-Of-Sight*) est bloqué et que le signal reçu est uniquement une réflexion ou une diffraction. L'erreur de mesure de la pseudo-distance est représenté par un délai de propagation, c'est-à-dire la différence entre la longueur du trajet emprunté par le signal réfléchi et le trajet direct (bloqué) entre le satellite et le récepteur. Cette erreur est toujours positive et, bien qu'elle se chiffre généralement par une dizaines de mètres, elle est potentiellement illimitée. Par exemple, les signaux reçus par réflexion à partir de grands bâtiments éloignés peuvent présenter des erreurs de plus d'un kilomètre. Cependant, l'intensité des signaux NLOS est très variable. Ils peuvent être très faibles, mais peuvent aussi être presque aussi forts que les signaux reçus directement. Les récepteurs à haute sensibilité peuvent donc recevoir beaucoup plus de signaux NLOS.

La réception NLOS et les interférences par trajets multiples peuvent se produire simultanément. Le cas le plus fréquent, est quand le signal direct d'un satellite est bloqué et des multiples signaux réfléchis sont reçus. Dans ce cas, l'erreur de mesure combinée peut être considérée comme la somme d'un signal NLOS et de plusieurs signaux réfléchis.

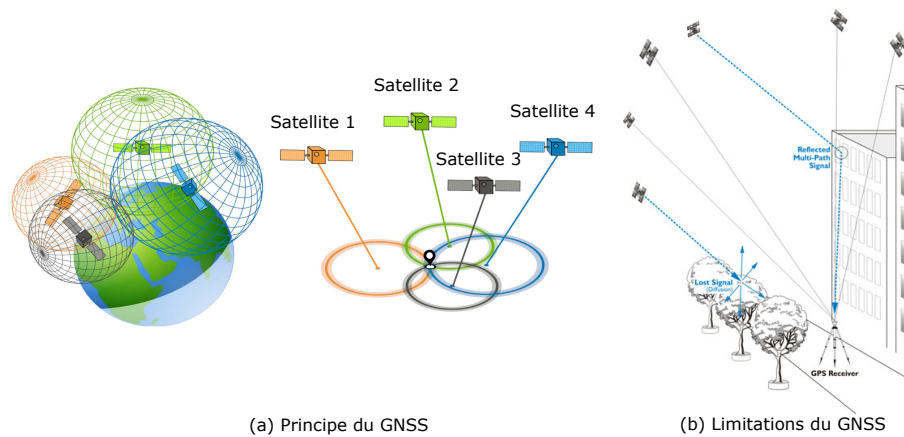


FIGURE 2.1 – (a) Principe du système de positionnement par satellites, (b) ses limitations

2.2.2 Les capteurs proprioceptifs :

Odomètres

Il s'agit d'une technique de localisation relative qui est utilisée pour mesurer la distance parcourue par un véhicule. Il s'agit d'un dispositif simple qui peut être mis en œuvre dans des applications en temps réel. Un odomètre peut être numérique ou mécanique. En ce qui concerne son mode de fonctionnement, la plupart des odomètres fonctionnent en comptant les rotations des roues et supposent que la distance parcourue est le nombre de rotations des roues multiplié par la circonférence de la roue. L'odomètre se base sur les mesures fournies par les encodeurs incrémentaux des roues pour déterminer la position du véhicule. Cette technologie est dans de nombreuses applications sujette au phénomène de glissement de roues.

Gyroscopes C'est un capteur proprioceptif qui mesure la vitesse angulaire ou la vitesse de rotation du corps sur lequel il est placé par rapport au repère inertiel. De nombreuses technologies existent [161] : le gyroscope mécanique se base sur le principe de conservation du mouvement cinétique et de la force de Coriolis, le gyroscope optique se base sur l'effet Sagnac, d'autres gyroscopes se basent sur des structures vibrantes notamment la technologie *Micro Electro-Mechanical Systems* (MEMES) qui permet de concevoir des capteurs de la taille d'une puce électronique. La mesure du gyroscope est ensuite intégrée au cours du temps pour estimer l'orientation du système. Sur la base du déplacement élémentaire proposé par l'odomètre et de la rotation élémentaire estimée par le gyroscope, la position et l'orientation du véhicule sont calculées [1].

Notons que, la position de départ doit être connue dans la mesure où l'information reconstruite est relative.

les systèmes inertiels Un système inertiel est une combinaison de capteurs, capables de déterminer les états de navigation d'un véhicule en mouvement, soit sa position, sa vitesse et son attitude.

Généralement, ces capteurs sont composés d'accéléromètres, de gyroscopes et dans certains cas des magnétomètres. Il existe des systèmes inertiels à :

1. 6 degrés de liberté dont 3 accéléromètres et 3 gyroscopes.
2. 9 degrés de liberté dont 3 accéléromètres, 3 gyroscopes et 3 magnétomètres.
3. 10 degrés de liberté dont 3 accéléromètres, 3 gyroscopes, 3 magnétomètres et un capteur de pression barométrique pour calculer l'altitude.

Ces systèmes peuvent être classés en trois types différents, ce qui suscite une certaine confusion. Le système le plus simplifié est appelé *Inertial Sensor Assembly* (ISA). Il produit des données brutes issues des capteurs inertiels, comme l'accélération et la vitesse angulaire. Dans le cas où, la sortie de l'ISA est compensée en termes d'erreurs, par exemple le biais et le facteur d'échelle, elle est appelée *Inertial Measurement Unit* (IMU). Dans la littérature, il existe différents types de capteurs IMU :

- IMU basée sur *Fiber Optic Gyroscope* (FOG)
- IMU basée sur *Ring Laser Gyroscope* (RLG)
- IMU basée sur les technologies MEMES

Finalement, si la sortie de l'IMU est traitée en appliquant des algorithmes de navigation qui déterminent la position, la vitesse et l'attitude. Le dispositif de fixation est appelé *Inertial Navigation System* (INS). Une INS est également capable de fournir en sortie les données inertielles brutes, seulement corrigées par l'IMU [161]. La différence entre les concepts est illustrée à la figure 2.2 :

Généralement, les systèmes de navigation inertielle utilisés sont présentés sous une forme qui appartient à deux catégories de base comme présenté sur la figure 2.3 :

-Les systèmes à plateforme stable : où les capteurs inertiels sont montés sur une plateforme à cardan fixée indépendamment de toute rotation externe.

-Les systèmes de strapdown : contrairement au systèmes à plateformes stables, les capteurs sont directement montés sur le dispositif créant ainsi un ensemble.

2.2.3 Les capteurs extéroceptifs

LIDAR Pour Light Detection And Ranging. C'est un capteur actif avec une combinaison spéciale de laser et de balayage 3D [199], il s'agit d'une technologie de télédétection permettant de mesurer les distances par rapport à une source de lumière laser. Le LiDAR est

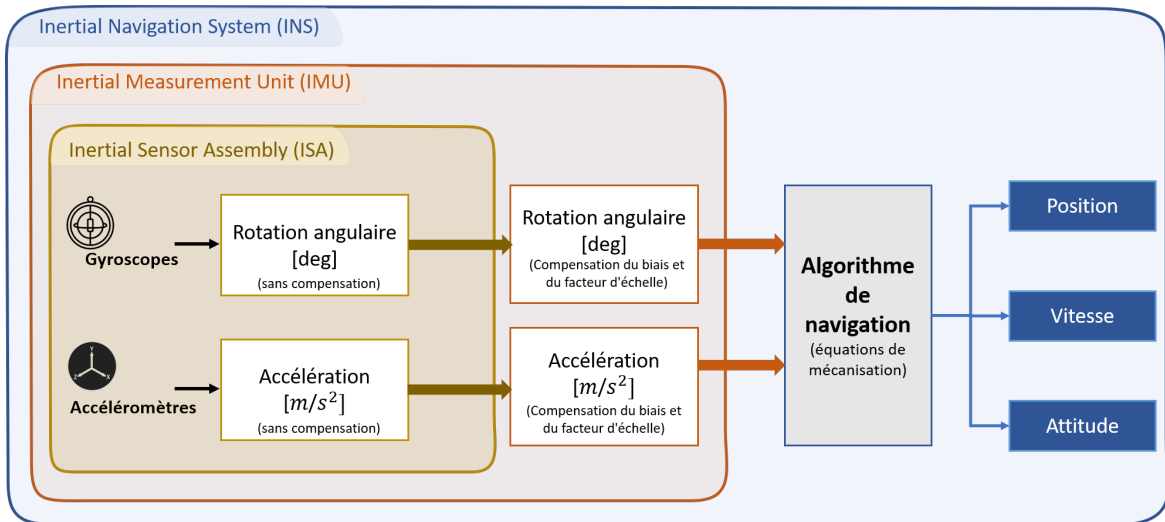


FIGURE 2.2 – Différence entre ISA, IMU et INS, adaptée de [161]




FIGURE 2.3 – Schéma de la plateforme « stable » et de la plateforme « strapdown » ([137])

une technique largement utilisée dans différents domaines : applications terrestres, aériennes, mobiles, véhicules autonomes ([34], [150], [124]). Il peut être adapté pour détecter des objets dans des conditions de mode nocturne et peut avoir une haute résolution avec une grande précision de position (voir figure 2.4). Il recueille un ensemble géoréférencé de nuages de points denses. Puis en calculant les différences de temps de retour du laser et de longueurs d'onde, une carte tridimensionnelle avec des formes détaillées est produite [165].




FIGURE 2.4 – mode de fonctionnement du LIDAR au niveau aérien et terrestre

RADAR Le radar est une technologie qui utilise des ondes radio pour mesurer la distance, l'angle et la vitesse des objets. Son principe de fonctionnement est basé sur le rayonnement électromagnétique qui peut être utilisé dans plusieurs bandes de fréquences (par exemple, $24GHz$, $77GHz$, $79GHz$). La fréquence la plus élevée donne une meilleure résolution qui permet au système de détection radar de distinguer plusieurs objets en temps réel. Les capteurs radar sont classés comme étant de courte à moyenne portée ($50 - 100m$). Cependant, certains capteurs radar sont capables de détecter un objet à une distance de plus de $150m$ [119]. Les capteurs radar offrent de nombreux avantages pour les véhicules autonomes en raison de leur robustesse dans toutes sortes de conditions environnementales. Ces systèmes sont conçus pour fournir fonctions de régulation de vitesse et de détection des collisions. Une autre caractéristique importante de ces capteurs, est qu'ils sont également capables de déterminer le mouvement relatif des objets détectés [156].

Caméra Une caméra fonctionne sur le principe de capteurs de lumière passifs pour produire une image numérique d'une région couverte. Les caméras sont capables de détecter des objets statiques et mobiles dans leur environnement qui les entoure. Elles ont la capacité de détecter les couleurs et les textures. Les caméras sont également capables de déterminer la distance d'un objet particulier, mais cela nécessite des algorithmes de traitement assez complexe. Généralement, on peut définir deux types de caméras ; caméra à vision stéréo et à vision monoculaire [22]. Les caméras à vision stéréo utilise deux objectifs, ils récupèrent les informations structurelles en 3D peuvent être récupérées en comparant la même scène sous deux angles différents. Alors que les caméra à vision monoculaire consiste à utiliser une seule caméra. Contrairement à la caméra stéréo, qui peut récupérer les informations de profondeur pour des scènes ayant des perspectives différentes, il est plus difficile d'observer les informations de profondeur en utilisant une seule caméra.

La cartographie C'est la réalisation et l'étude des cartes géographiques qui traite deux informations fondamentales : La position et l'information qui y est rattachée. Il existe plusieurs types de cartes cités dans [157]. Il s'agit notamment des cartes topographiques, qui présentent les relations spatiales entre différents objets géographiques, les cartes spéciales telles que les cartes maritimes ou aéronautiques, les cartes numériques telle que la cartographie 2D embarquée dans nos smartphones qui est une carte routière numérique sous la forme d'une base géographique vectorielle 2D. Il existe également la cartographie 3D qui donne une représentation 3D d'une image réelle d'un environnement.

2.3 Fusion multi-capteurs

La fusion de données, également appelée fusion de données multi-capteurs, fusion d'informations ou fusion de capteurs, a reçu plusieurs définitions de différents auteurs dans la littérature [[204] [126], [17], [100], [45], toutefois une meilleure compréhension de ce principe peut être obtenue en répondant aux questions suivantes :

- Qu'est-ce qui est impliqué dans la fusion de données ?

Combiner, fusionner ou intégrer des données homogènes ou hétérogènes.

- Quel est l'objectif de la fusion de données ?

Obtenir une meilleure représentation d'un processus ou de l'environnement, déduire des informations sous-jacentes, améliorer la qualité des données.

- Comment appliquer la fusion de données ?

En général, il est difficile d'utiliser une unique source indépendante pour générer des données et surtout de les utiliser dans des applications complexes, telles que le véhicule autonome qui exige un taux élevé de sûreté, un certain niveau de précision et de disponibilité. En effet, les informations données par des capteurs peuvent être imprécises et très sensibles aux conditions climatiques et aux éléments de l'infrastructure ce qui peut dégrader leurs performances et affecter la sûreté de fonctionnement du système globale. Les conditions de l'environnement ont un effet considérable sur les données de mesure des capteurs. Par exemple, la faible luminosité de la nuit dégrade les performances des caméras couleur. En outre, les technologies GNSS sont affectés par les perturbations dans certaines situations, comme les tunnels et les forêts où les signaux peuvent être masqués ou réfléchis. Certaines sources de dégradation des performances sont dues à des erreurs de dérive, où un petit biais des accéléromètres ou/et des gyroscopes peut conduire à une erreur considérable lorsque les mesures sont accumulées au fil du temps, comme dans le cas de l'IMU [146].

En revanche, les erreurs peuvent être dues à la faible résolution du capteur, aux irrégularités de la surface ou au glissement des roues, comme c'est le cas pour les odomètres intégrés aux roues. Enfin, elles peuvent être dues à l'incertitude des mesures. Cependant les performances des capteurs varient, et un capteur jugé peu fiable en général peut s'avérer plus précis que les autres pour des conditions de route particulières. Tous ces capteurs présentent des avantages ainsi que des limites dans différentes conditions environnementales, d'où l'importance et la nécessité de fusionner les données de ces capteurs. L'objectif de la fusion consiste à combiner ou à fusionner des informations obtenues de plusieurs sources et à exploiter ces informations dans diverses tâches telles que prendre des décisions, et estimer des valeurs numériques. Ces sources sont généralement en robotique, des capteurs physiques qui observent la situation réelle et qui fournissant différentes informations sur les événements potentiels.

D'autres définitions du concept de fusion de données peuvent être trouvées dans [17]. La

fusion de données multi-capteurs combine les mesures de plusieurs capteurs pour former une représentation plus fidèle et plus pratique à utiliser de la situation observée : *le modèle du monde*. Elle cherche à exploiter toutes les informations disponibles sur un système donné et son environnement pour contourner les imperfections de chaque source et améliorer la robustesse du process de fusion de données. La fusion de données a connu une longue histoire dans le domaine de la robotique. Elle a fait l'objet d'une attention particulière au cours des années 80-90 dans les applications militaires [69, 70], et reste toujours d'actualité dans ce domaine. Les méthodes de fusion ont été adaptées et développées pour des applications robotiques (telles que la navigation autonome, le suivi de la trajectoire et la localisation).

Pour la localisation d'un véhicule autonome, le but de la fusion de données est de maximiser la précision de l'estimation de la position par une redondance d'informations causée par la multiplication des mesures fournies par des capteurs similaires ou dissemblables. A chaque instant ces informations fournies par ces capteurs sont fusionnées en tenant compte également des informations des instants précédents. En effet, c'est une approche à plusieurs niveaux, qui dépend de la nature des capteurs, du contexte, du type de données, et de l'application. Dans la littérature, les chercheurs utilisent différentes combinaisons de technologies comme le GNSS, l'IMU, l'odomètre, le LiDAR et les caméras, etc pour fusionner leurs données à différents niveaux afin de compenser les limites des capteurs individuels et obtenir une position précise et fiable.

Traditionnellement, les systèmes GNSS ont été un outil majeur pour la localisation et la navigation dans un environnement à ciel dégagé. Les GNSS peuvent non seulement fournir une position n'importe où sur terre, de haute précision et en temps réel, mais aussi une précision à long terme [116]. Malgré ces avantages, ils ne peuvent fournir des solutions fiables que lorsque le nombre de satellites visibles est supérieur à quatre et que le bruit de mesure n'est pas significatif. Cela peut constituer un inconvénient majeur lorsque le GNSS fonctionne seul surtout lorsque la sûreté de fonctionnement du système et la disponibilité de la solution sont des exigences strictes, le GNSS seul risque de ne pas fournir de résultats satisfaisants dans des environnements contraints, tels que les canyons urbains, les forêts ou les tunnels. Il est courant que les signaux GNSS soient bloqués ou interrompus dans certaines conditions environnementales [148].

Par conséquent, pour compenser les pertes ou les interruptions de signal GNSS, le système de localisation est susceptible d'être couplé à d'autres capteurs. L'intégration du GNSS et de l'INS a été largement déployée en raison de leurs caractéristiques complémentaires sur plusieurs aspects ; D'une part, les systèmes INS (les mesures fournies par le capteur IMU) sont plus fidèle à court terme, ils peuvent fournir des mesures à une fréquence très élevée autour 50 Hz alors que le GNSS sa fréquence d'acquisition c'est entre 1 et 20 Hz maximum et ils peuvent également fournir des informations sur l'attitude [143]. D'autre part, le GNSS est plus juste sur le long terme et l'erreur est effectivement invariante dans le temps [116].

Par conséquent, l'intégration GNSS/INS peut fournir des performances supérieures à celles d'un système GNSS ou INS indépendant [167]. En plus, les deux technologies sont à faible coût ce qui rend l'approche plus attractive.

Cependant, dans les environnements urbain ou boisés en raison de la perte de signal GNSS due à la couverture (les satellites sont souvent bloqués par les bâtiments ou les arbres) et aux effets de trajets multiples, la précision de positionnement du GNSS est sévèrement dégradée. Dans cette situation, les performances de l'intégration GNSS/INS dépendent fortement de la qualité de l'unité de mesure inertielle (IMU) adoptée. Par conséquent, si l'on n'utilise une IMU à faible coût, la précision du positionnement se dégradera rapidement [60], [136]. La technique généralement utilisée pour compenser cette limitation est l'utilisation d'un système de capteurs auxiliaires, tels qu'un odomètre [168] (voir figure 2.5), ou des technologies plus coûteuses comme LIDAR, cartographie et caméra. Néanmoins, cette utilisation de capteurs externes limite les domaines d'application de ces systèmes de navigation, et augmente également le coût de conception du système. Le tableau ci-dessous 2.1 présente quelques travaux qui proposent la fusion multi-capteurs avec les différentes technologies présentées précédemment pour améliorer les performances de la fonction de localisation et de la navigation d'un véhicule autonome.




FIGURE 2.5 – Complémentarité entre les capteurs et l'intérêt de la fusion de données

2.4 Complémentarité et techniques de fusion de données

Une grande importance doit être accordée au choix de la méthodologie dont les mesures des capteurs sont combinés et traités lors de développement de l'architecture de fusion multi-capteurs. En effet, la technique choisie influence directement la qualité de l'estimation de position et le temps de calcul qui doit être contrôlé afin d'étudier la faisabilité de l'approche si on souhaite l'appliquer en temps réel. Dans la littérature, Les systèmes GNSS et l'INS sont très souvent couplés dans la mesure où la complémentarité de ces technologies permet

2.4. COMPLÉMENTARITÉ ET TECHNIQUES DE FUSION DE DONNÉES

Travaux	Les capteurs fusionnés	Avantages de fusion	Limitations de fusion
[143], [66], [49], [202]	GNSS/INS	Navigation continue ; Correction des mesures GNSS par INS	Coupure du signal GNSS dans les zones urbaines ; Dérive des mesures INS, sensible au champs magnétique
[139], [174], [169]	GNSS/INS/Map/vision	Positionnement latéral précis grâce à la détection des marquages routiers et à la cartographie HD	Interruption du signal GNSS ; dérives de l'INS ; manque de précision de la carte HD et visibilité des marquages routiers.
[31], [133]	GNSS/INS/LiDAR	Positionnement précis, Calibrage du nuage de points LiDAR dispersés avec l'image	Perte du signal GNSS, faible résolution de la reconstruction de la scène 3D par LiDAR lorsqu'il est utilisé seul
[9], [178], [130]	GNSS/fish-eye caméra	Positionnement précis dans les zones urbaines, Les images améliorent la compréhension de la scène, en particulier pour les surfaces réfléchissantes	Sensible à la qualité de l'éclairage, la couverture nuageuse, les conditions d'illumination et les conditions météorologiques
[121], [140]	GNSS/INS/Odomètre	Positionnement précis à moins d'un mètre, les erreurs de INS sont compensées par l'odomètre	masquage satellitaire dans les zones boisées et urbaines, Dérive à long terme INS et odomètre, Sensible à l'état des routes

TABLE 2.1 – Les différentes technologies fusionnées avec les avantages et inconvénients

de combler les inconvénients de l'une des technologies par les avantages de l'autre (voir Table 2.2).

	Avantages	Inconvénients
GNSS	<ul style="list-style-type: none"> • Auto-initialisation • Les erreurs sont bornées • Un coût relativement faible • Justesse à long terme 	<ul style="list-style-type: none"> • Une précision d'attitude limitée • Sensible aux interférences • Faible quantité de données Infrastructure coûteuse
INS	<ul style="list-style-type: none"> • Importante quantité de données • Avoir des informations sur la translation et la rotation • Indépendante (non susceptible aux interférences) 	<ul style="list-style-type: none"> • Les erreurs ne sont pas bornées • Exige la connaissance du champ de gravité • Nécessite la fixation des conditions initiales

TABLE 2.2 – Les avantages et inconvénients des technologies GNSS et IMU.

Les systèmes GNSS proposent un positionnement qualifié de juste mais peu précis, lorsque le positionnement par IMU est au contraire précis mais peu juste. On espère généralement, en combinant les mesures GNSS et IMU atteindre une haute précision, une haute disponibilité, et une meilleure intégrité. Mais il existe différentes possibilités de combinaison entre les données GNSS et les données IMU. La méthode de couplage lâche proposée dans [181] pour la localisation d'un véhicule montre une amélioration de la précision de localisation latérale et longitudinale à un niveau décimal dans le cas où l'environnement ne présente pas de contraintes, le masquage des satellites par les bâtiments dégradant la disponibilité du système. Mais les indicateurs de performances importants ne se limitent pas à la précision.

L'intégrité est également cruciale pour les véhicules autonomes, dans les travaux [172] les auteurs démontrent l'intérêt d'utiliser un couplage serré dans les environnements où le

masquage satellitaire peut devenir important. Dans [145] les auteurs implémentent différentes méthodes de couplage ultra-serré qui permettent d’atteindre des performances avancées, il s’agit de suivre la phase porteuse du signal émis pour avoir plus de précision sur l’erreur dans un milieu contraignant.

2.4.1 Architectures de couplage des mesures GNSS et INS

Dans cette section, nous détaillons les stratégies d’intégration GNSS/INS les plus utilisées dans la littérature : le couplage lâche, le couplage serré et ultra-serré.

2.4.2 Couplage lâche

Le couplage lâche est le schéma d’intégration GNSS/INS le plus courant, où les positions et les vitesses dérivées par le traitement des signaux GNSS sont fusionnées en tant que mises à jour des informations de la position estimée par INS, par le biais d’un estimateur d’état par exemple le filtre de Kalman (KF) [4]. Pour améliorer d’avantage la précision de la solution de navigation, les erreurs sont renvoyées aux équations de mécanisation de l’INS [185] pour en atténuer les effets à la prochaine itération [60]. Le vecteur d’état du système est composé de 15 variables, comprenant la position (latitude, longitude et altitude), la vitesse dans les trois directions, l’attitude (roulis, tangage, lacet) ainsi que le biais des accéléromètres et des gyroscopes [54]. La figure 2.6 montre le schéma fonctionnel d’une architecture à couplage lâche.




FIGURE 2.6 – Schéma fonctionnel du couplage lâche INS/GNSS, adaptée de [143]

2.4.3 Couplage serré

Il est difficile, dans certaines conditions, de maintenir la continuité de la navigation en utilisant une intégration GNSS/INS à couplage lâche, en raison du blocage de la réception des signaux pour le GNSS et de l'accumulation d'erreurs au fil du temps du système de navigation inertielle. Afin d'assurer l'intégrité du système et de maintenir la continuité de la position pendant la navigation malgré les conditions critiques, un couplage serré peut résoudre le problème [107], [144], [203], [63]. La différence entre le couplage lâche et le couplage serré se trouve au niveau de la profondeur d'intégration et donc de l'utilisation des données récoltées plus ou moins tôt dans la chaîne du traitement de signal.

En effet, le couplage lâche traite la différence entre les positions du GNSS et INS tandis que le couplage serré intervient au niveau de la différence entre les pseudo-distances de GNSS et les pseudo-distances virtuelles de l'INS. Les états d'erreurs de l'intégration sont composés d'erreurs de navigation, d'erreurs des capteurs inertiels et d'erreurs d'horloge du récepteur GNSS. L'estimation du filtrage qui représente les erreurs des capteurs inertiels et les erreurs d'horloge des récepteurs GNSS est utilisée comme retour d'information pour calibrer le biais des accéléromètres et gyroscopes. De plus, en ajoutant ces erreurs d'estimation à la solution de navigation de la dernière époque, nous modifions les résultats de navigation directe de l'INS et nous compensons ses erreurs pour l'estimation de la position, vitesse et attitude (PVA) de l'époque suivante. La figure 2.7 montre l'intégration du couplage serré GNSS/INS. Les mesures brutes GNSS pour chaque satellite i , combinées aux mesures de l'INS, sont utilisées pour l'intégration stochastique.

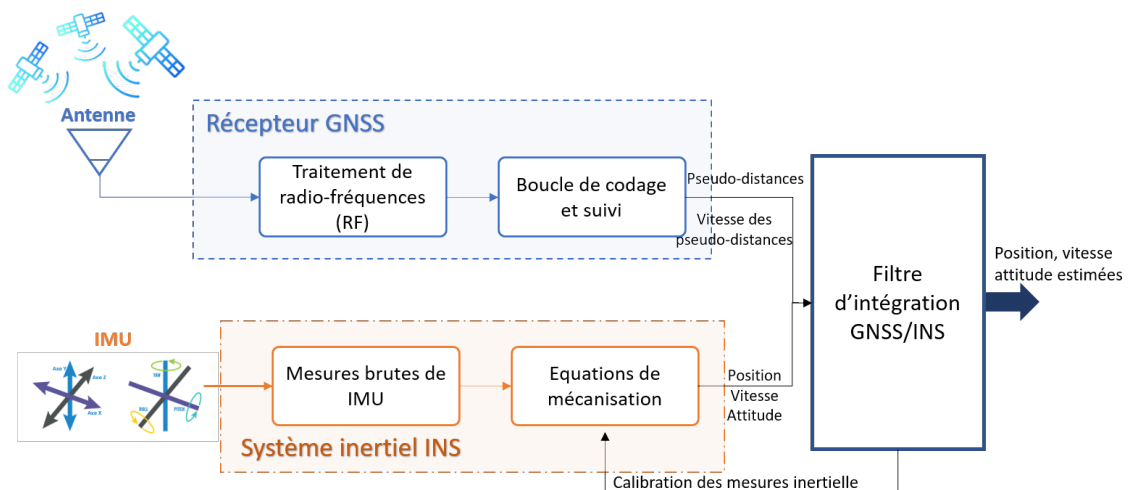


FIGURE 2.7 – Schéma fonctionnel du couplage serré INS/GNSS, adaptée de [143]

Le tableau 2.3 présente un comparatif en terme d'avantages et inconvénients des architectures proposées précédemment (couplage lâche, serré et ultra-serré).

Implémentation	Avantages	Inconvénients
Couplage lâche	<ul style="list-style-type: none"> • Application simple. • Robustesse (les capteurs s'entraident). • Temps de calcul réduit. 	<ul style="list-style-type: none"> • Impossible de fournir une mise à jour des mesures à partir du filtre GNSS, lorsque la disponibilité du GNSS est mauvaise.
Couplage serré	<ul style="list-style-type: none"> • Peut être utilisé dans l'environnement urbain (moins de 4 satellites). • Faible disponibilité des satellites. • Les pseudo-distances brutes et prédites peut conduire à des résultats. 	<ul style="list-style-type: none"> • L'augmentation de la taille du vecteur d'état entraîne un temps de traitement important.
Couplage ultra-serré	<ul style="list-style-type: none"> • Réduit le stress dynamique sur le récepteur, l'influence du bruit thermique, la bande-passante de la boucle du récepteur. • Anti brouillage du signal. • Réacquisition du signal GNSS perdu. 	<ul style="list-style-type: none"> • La réalisation de ce principe de couplage nécessite un composant matériel spécial et des accès au micrologiciel du récepteur. • L'implémentation ne peut être effectuée que par les fabricants du matériel.

TABLE 2.3 – Une comparaison des architectures les plus utilisées en intégration INS/GNSS

2.4.4 Couplage ultra-serré

Bien que les intégrations lâche ou serrée offrent des performances dans certains environnements. Ils restent sensibles aux environnements de signaux faibles ou brouillés. Une stratégie d'intégration ultra-serrée (ou profonde) a été proposée par des chercheurs pour améliorer les performances dans les environnements à faible signal ou à signal brouillé [145]. L'intégration profonde, également appelée ultra-serrée, combine le suivi des signaux GNSS et l'intégration GNSS/INS en une seule étape. Le récepteur GNSS n'est plus une source d'information indépendante puisque son fonctionnement dépend également en partie des informations de l'INS. L'intégration profonde représente une fusion optimale des informations provenant d'une INS et d'un récepteur GNSS [55]. Toutefois, les avantages potentiels décrits ci-dessus peuvent être obtenus au détriment d'une complexité considérablement accrue, d'une charge de calcul plus importante et d'exigences de synchronisation temporelle strictes [55, 185].

2.5 Les techniques existantes d'estimation de position d'un véhicule

L'objectif principal du processus d'estimation est de minimiser l'estimation de l'erreur d'état tout en étant robuste aux incertitudes et aux perturbations. Dans cette section, nous présentons le principe de techniques d'estimation qui permettent de répondre à ces besoins. Cependant, lorsqu'il s'agit d'estimation d'état pour les systèmes non linéaires comme la dynamique d'un véhicule autonome, il n'existe pas de solution unique. Dans la littérature, ils existent une multitude de solutions. Elles peuvent être classées en deux catégories : les méthodes théoriques d'intégration classique et les méthodes d'apprentissage profond. Les al-

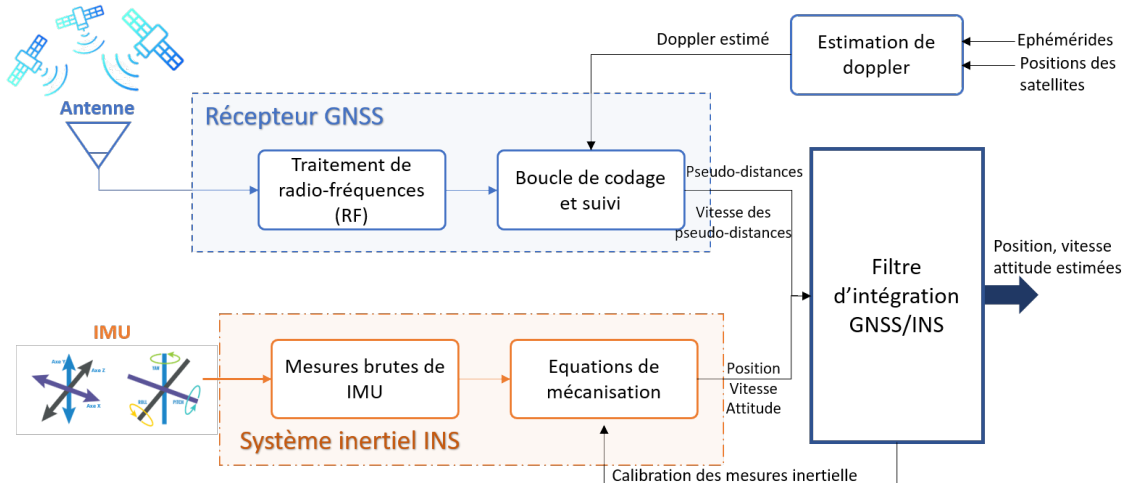


FIGURE 2.8 – Schéma fonctionnel du couplage ultra-serré INS/GNSS, adaptée de [143]

algorithmes classiques utilisent la fusion de données pour le développement des applications qui exigent la modélisation et la gestion des imperfections des données (imprécision, incertitude).

Ces algorithmes appliquent des approches basées sur des théories de l'incertitude. Elles comprennent les méthodes probabilistes, les méthodes statistiques, les méthodes basées sur la connaissance (logique floue et possibilité), les méthodes d'analyse d'intervalle et les méthodes de raisonnement fondé sur la preuve (figure 2.9). Pour résumer brièvement les algorithmes classiques les plus utilisés, ainsi que leurs avantages et inconvénients (voir tableau 2.4). Dans notre travail, nous nous focalisons sur le cadre probabiliste. Ces méthodes offrent un cadre mathématique puissant ainsi que de nombreux outils statistiques qui nous permet de concevoir un système de localisation intègre, précis et disponible dans des contextes de navigation différents.

Algorithmes	Caractéristiques	Avantages	Inconvénients
Méthodes statistiques	Utilisées pour optimiser le traitement des données en utilisant un modèle statistique pour modéliser les données des capteurs	Peuvent gérer des corrélations inconnues ; tolérantes	Limitées aux estimateurs linéaires ; la complexité de calcul est élevée
Méthodes probabilistes	Basées sur la représentation des probabilités pour les données des capteurs	L'incertitude dans l'information fournie est gérée, traitent les systèmes non linéaires (UKF, ...)	Nécessite une connaissance a priori du modèle des systèmes et des données
Méthodes basées sur les connaissances	Utilisent des approches d'intelligence artificielle inspirées des mécanismes de l'intelligence humaine	Gèrent l'incertitude et l'imprécision ; capacité à gérer des systèmes non linéaires complexes	Dépendent de l'expertise et de l'extraction des connaissances.
Méthodes de raisonnement fondé sur la preuve	Dépendent du mécanisme de combinaison de Dempster pour mettre en œuvre le modèle	Le degré d'incertitude est attribué à l'information fournie, identification d'une situation problématique, modélisation d'une hypothèse complexe	Complexité de calcul élevée, exigent l'hypothèse d'une preuve
Méthodes d'analyse d'intervalle	Partage de l'espace opérationnel en intervalles, Résolution de problèmes de satisfaction de contraintes	Garantie d'intégrité, capacité à traiter des systèmes non linéaires complexes	Discretisation de l'espace opérationnel, complexité de calcul élevée

TABLE 2.4 – Les algorithmes classiques de fusion avec les caractéristiques, les avantages et inconvénients

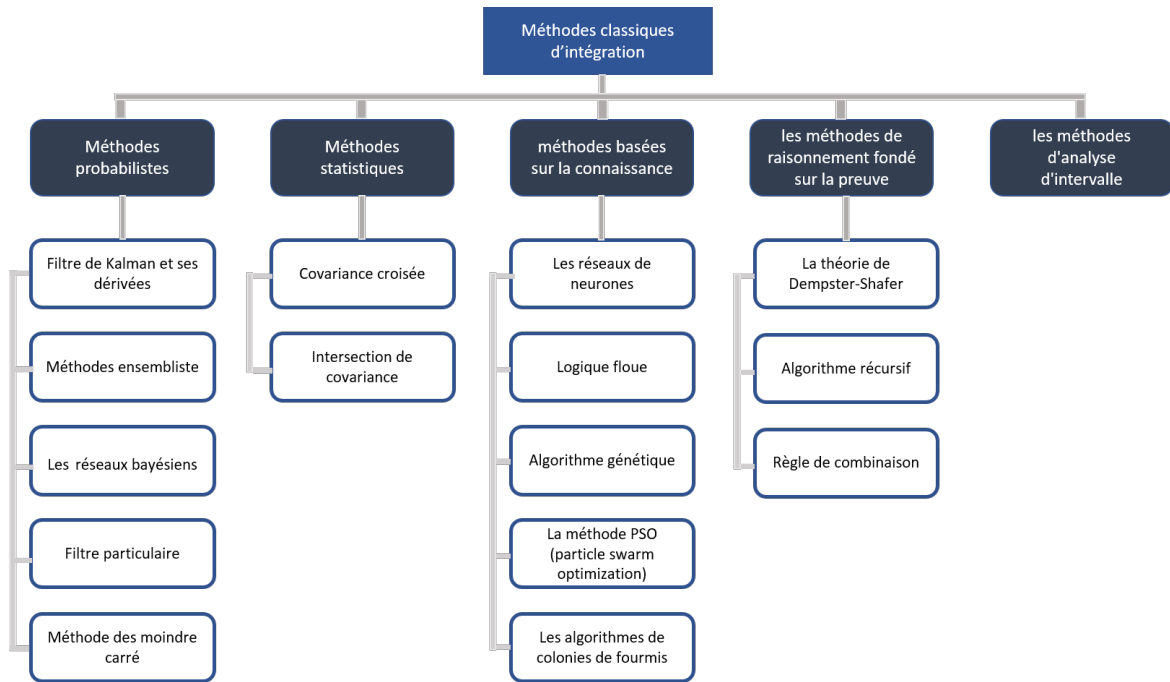


FIGURE 2.9 – Les méthodes classiques utilisées pour la fusion des données, adaptée de [26]

2.5.1 Les méthodes probabilistes

Les méthodes d'estimation d'état probabilistes ont une longue histoire. En 1809, Gauss a proposé une méthode d'optimisation appelée la méthode des moindres carrés pour déterminer l'orbite d'un corps céleste à partir de mesures. Étant donné que la méthode des moindres carrés n'a pas besoin de connaître les connaissances statistiques préalables du signal lors de l'estimation. La méthode des moindres carrés a un large panel d'applications dans de nombreux domaines.

Dans les années 1940, pour contrôler la puissance de feu, Wiener et al [205] ont conçu le filtre de Wiener dans le domaine fréquentiel pour obtenir une estimation dynamique linéaire optimale dans un système de processus aléatoire stationnaire. Par le calcul de l'équation de Wiener-Hopf, le filtre de Wiener obtient la solution analytique de la fonction de transfert optimale du filtre, qui peut supprimer ou passer les signaux contenant une variété d'information. En revanche, le filtre de Wiener exige certains critères pour l'estimation :

- L'état estimé et la mesure doivent être conformes à un processus aléatoire stationnaire.
- L'équation de Wiener-Hopf doit être résolue dans le processus de filtrage.

Ces exigences peuvent augmenter la quantité de calculs et l'espace de stockage. Par conséquent, les applications des filtres de Wiener sont limitées. Pour pallier les insuffisances des filtres de Wiener, Rudolf Emil Kalman a proposé en 1960 une théorie moderne du filtrage [92]. Il a introduit les modèles d'état dans la théorie de l'estimation stochastique pour décrire

la relation entre les états et les mesures. Il a estimé les états sur la base des mesures en utilisant des prédictions et des mises à jour. Le filtre de Kalman (KF) est le premier à être développé. Son objectif principal est d'évaluer de manière récursive l'état d'un système dynamique à partir d'une série de mesures bruitées. En fonction de l'estimation de l'état à l'instant précédent et les informations de mesure actuelles, une nouvelle estimation peut être calculée selon la méthode récursive, ce qui réduit les besoins en capacité de stockage et de calcul de l'ordinateur et améliore le traitement en temps réel. Simultanément, le filtre de Kalman peut estimer des processus aléatoires stationnaires unidimensionnels et des processus aléatoires non stationnaires multidimensionnels.

Après l'apparition du filtre de kalman, des variantes du KF sont formulées pour la prise en compte de modèles non linéaires comme le filtre de Kalman étendus (EKF) qui utilisent la linéarisation de premier ordre présentée dans [106], et l'EKF du deuxième ordre utilisant la série de Taylor à l'ordre 2 dans [132]. Par la suite, d'autres méthodes ont été introduites tels que le filtre particulaire (PF), et le filtre de Kalman non parfumé (UKF). Dans cette étude, on s'intéresse aux filtres stochastiques dans le but de profiter de la capacité de ces méthodes à prédire des paramètres et de rectifier des erreurs, non seulement des capteurs, mais aussi du modèle afin de développer une méthode de localisation précise du véhicule. La section suivante présente brièvement les méthodes de filtrage stochastique les plus utilisées dans la littérature.

Les filtres stochastiques

Les filtres stochastiques ont été largement utilisés dans la fusion multi-capteurs en raison de leur simplicité et de leur facilité de mise en œuvre. Le premier filtre conçu c'est le KF. Dans la prochaine section, une brève présentation de ce filtre est proposée.

Le filtre de Kalman c'est un estimateur récursif. Il utilise un modèle mathématique du système supervisé pour prédire l'état du système à partir des mesures bruitées tout en minimisant l'erreur quadratique moyenne à un instant donné. Cette prédiction est ensuite mise à jour en fonction des nouvelles données provenant des capteurs. L'estimation qui en résulte est plus précise que ne le serait la performance d'un seul capteur. Considérons le système linéaire suivant défini par son modèle d'état décrivant l'évolution du système et par son modèle d'observation :

$$X_{k+1} = F_k X_k + B_k u_k + w_k \quad (2.3)$$

$$Z_k = H_k X_k + \epsilon_k \quad (2.4)$$

Où :

X_k est le vecteur d'état

F_k est la matrice d'état

u_k est le vecteur d'entrée

B_k est la matrice d'entrée

Z_k est le vecteur d'observations

H_k est la matrice d'observations

$w_k \sim \mathcal{N}(0, Q_k)$ est le bruit du modèle considéré comme un bruit blanc gaussien de moyenne nulle et de matrice de covariance Q_k^u

ϵ_k est le vecteur de bruit d'observation considéré comme un bruit blanc gaussien de moyenne nulle et de matrice de covariance $R_k = E[\epsilon_k \epsilon_k^T]$

Les bruits w_k et ϵ_k sont indépendants entre eux.

Le filtre de Kalman alterne entre deux étapes principales appelées étape de prédiction (*a priori*) et étape de correction ou de mise à jour (*a posteriori*). Au cours de ces deux étapes, la matrice d'information et le vecteur d'information sont calculés. Dans l'étape de prédiction, l'estimation est calculée en utilisant l'estimation de l'état précédent et les observations ne sont pas incluses à ce niveau. Cette estimation est corrigée en utilisant les observations reçues à l'étape actuelle par l'étape de correction.

◦ Étape de prédiction

L'estimation de l'état $X_{k+1|k}$ et de la matrice de covariances $P_{k+1|k}$ du système s'écrivent comme suit :

$$X_{k+1|k} = F_k X_k + B_k u_k \quad (2.5)$$

$$P_{k+1|k} = F_k P_k + F_k^T + Q_k^u \quad (2.6)$$

◦ Étape de correction

$$X_{k+1|k+1} = X_{k+1|k} + K_{k+1} \tilde{y} \quad (2.7)$$

$$P_{k+1|k+1} = P_{k+1|k} - K_{k+1} S_{k+1} K_{k+1}^T \quad (2.8)$$

Où \tilde{y} est l'innovation calculée comme suit :

$$\tilde{y} = Z_k - H_k X_{k+1|k} \quad (2.9)$$

K_k est considéré comme le gain de kalman et s'écrit de la façon suivante :

$$K_{k+1} = P_{k+1|k} H_k^T S_{k+1}^{-1} \quad (2.10)$$

S_k est la matrice de covariances des innovations :

$$S_{k+1} = H_k P_{k+1|k} H_k^T + R_k \quad (2.11)$$

L'un des principes du KF est qu'il suppose que les erreurs sont gaussiennes et peut traiter les modèles linéaires.

Cependant, le KF standard nécessite un modèle précis, les caractéristiques statistiques connues du bruit du système. Ces exigences sont relativement sévères dans les applications. Pour les systèmes réels avec une non linéarité significative (par exemple un véhicule autonome), ses performances peuvent se dégrader de manière significative. Dans ce cas, le système ne peut pas remplir ces conditions en raison de certaines incertitudes, ce qui fait que le KF perd son optimalité, ce qui réduit la précision de l'estimation et conduit même à la divergence. Par conséquent, dans les années 1970, Bucy et Sunahara ont proposé le filtre de Kalman étendu (EKF).

Le système non linéaire est d'abord linéarisé et utilise ensuite le filtre de Kalman généralisé pour estimer l'état, formant ainsi une estimation robuste pour les modèles dynamiques non-linéaire. Malgré ses nombreux avantages, le EKF représente aussi certaines limitations, l'un des inconvénients principal du EKF est le temps de calcul nécessaire à l'étape de correction causée par l'inversion d'une matrice S_k . De plus, la structure du EKF ne permet pas d'isoler facilement une observation si on souhaite mettre en place une stratégie de diagnostic. En effet, il est nécessaire de recalculer l'ensemble des matrices. Afin de contourner ces problèmes, des chercheurs [62] ont proposé une forme informationnel du filtre de kalman (IF) et sa forme non linéaire (NIF) [65, 135], [2] dans le domaine de la fusion de données. Par ailleurs, plusieurs applications dans le domaine de la localisation et de la navigation emploient ce filtre.

Filtre informationnel Le IF s'avère être une méthode beaucoup plus directe et naturelle pour traiter les problèmes de fusion de données multi-capteurs que le KF ou d'autres estimateurs basés sur l'état. Il possède un certain nombre de propriétés utiles qui peuvent être exploitées dans le développement d'algorithmes et fournit une interprétation directe de l'observation et de la contribution des capteurs en termes d'information. Il est à noter que cette forme informationnelle est connue sous la représentation canonique ou naturelle de la distribution gaussienne.

Comme le KF, le IF est constitué d'une étape de prédiction et d'une étape de correction. Il utilise principalement la matrice de Fisher [154], la forme inverse de la matrice d'information. La matrice $Y_{k+1|k}$ et le vecteur d'information $y_{k+1|k}$ représentent les équations de prédiction dans l'espace d'état de l'information sont calculées comme suit :

$$Y_{k+1|k} = [P_{k+1|k}]^{-1} = [F_k P_k + F_k^T + Q_k^u]^{-1} \quad (2.12)$$

$$y_{k+1|k} = Y_{k+1|k} X_{k+1|k} \quad (2.13)$$

Par la suite, les équations sont mises à jour :

$$Y_{k+1|k+1} = Y_{k+1|k} + \sum_{i=1}^N gI_i(k) \quad (2.14)$$

$$y_{k+1|k+1} = y_{k+1|k} + \sum_{i=1}^N pI_i(k) \quad (2.15)$$

Où $gI_i(k)$ et $pI_i(k)$ sont les contributions informationnelles calculées comme suit :

$$gI_i(k) = H_{i,k}^T R_i^{-1}(k) H_{i,k} \quad (2.16)$$

$$pI_i(k) = H_{i,k}^T R_i^{-1}(k) Z_{i,k} \quad (2.17)$$

And N est le nombre d'observations à l'instant k .

Malgré leur nombreux avantages, le KF et ses variantes représentent certaines limitations. Par exemple, pour l'intégration des technologies GNSS/INS, ils comprennent la nécessité d'un modèle dynamique préinformé de toutes les erreurs INS et GNSS, l'observabilité de certains de ces états d'erreur et la dégradation des performances dans les cas de niveaux élevés de bruit des capteurs. En outre, la qualité des mesures et la précision finale des états de filtrage dépendent de la qualité du modèle dynamique conçu. Si le filtre est exposé à des données d'entrée qui ne correspondent pas au modèle dynamique conçu, il peut être instable et parfois diverge complètement [51].

2.6 Les méthodes d'apprentissage profond et leur rôle dans la fonction de localisation

2.6.1 L'apprentissage automatique et l'apprentissage profond

L'apprentissage automatique (machine learning ML) est un vaste domaine de recherche avec de nombreuses applications. Il est généralement classé en trois catégories principales, à savoir l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement. Néanmoins, il existe également d'autres combinaisons telles que l'apprentissage semi-supervisé. En outre, avec les progrès technologiques, l'apprentissage profond est en plein essor. De nombreuses techniques d'apprentissage automatique ont souvent une approche profonde ou sont combinées avec l'apprentissage profond (voir figure 2.10). L'apprentissage profond (Deep learning DL) est une évolution des réseaux de neurones traditionnels et constitue

une sous-catégorie de l'apprentissage automatique qui consiste à imiter la fonctionnalité du cerveau humain [61].

En termes d'architecture, ce qui rend l'apprentissage profond différent des réseaux de neurones traditionnels, ces algorithmes impliquent la conception de réseaux multiples comportant plusieurs couches (Nombre de couches cachées > 3), ce qui leur permet de traiter des données brutes, massives et d'extraire certains modèles pour effectuer des tâches complexes et intelligentes. Le concept fondamental de l'apprentissage profond repose sur les réseaux de neurones artificiels (artificial neural networks ANN), qui remontent à 1943, lorsque Walter Pitts et Warren McCulloch [131] ont fait les premiers pas vers la conception d'un modèle basé sur le principe de fonctionnement des réseaux neuronaux du cerveau humain. Si les bases de l'apprentissage profond ont été établies il y a longtemps, son émergence récente est due au développement de puissantes machines de calcul et à la disponibilité des "big data" nécessaires à l'entraînement des modèles. Récemment, les méthodes d'apprentissage profond sont appliquées à des problèmes réels nouveaux et passionnants dans les domaines suivants diagnostics médicaux, automatisation des usines, sécurité publique, sciences environnementales, le transport autonome, les applications militaires, et bien davantage [64], [7]. Dans le développement du véhicule autonome, ils ont été intégrés dans plusieurs applications. Dans [88], ils proposent une méthode de détection et de classification des LOS/ NLOS dans un milieu urbain basée sur le réseau neurones à convolution. Dans [94], ils utilisent les méthodes d'apprentissage profond pour la segmentation de l'environnement par exclusion des points caractéristiques qui existent dans le ciel et les voitures en mouvement. La diversité des architectures d'apprentissage profond ne cesse de croître à mesure que de nouvelles méthodes et techniques sont développées pour répondre à une grande variété de problèmes. Ces architectures se distinguent des modèles peu profonds principalement par leur topologie. Les plus fréquemment utilisées sont : la perceptron multicouche ((MLP), les réseaux de neurones convolutionnels (CNN), les réseaux de neurones récurrents (RNN), les réseaux de croyance profonds (DBN) et les autoencodeurs (AE).

L'avantage de conception de ces réseaux d'apprentissage profond c'est qu'ils sont composés de plusieurs couches qui forment des approximateurs universels capables d'apprendre n'importe quelle fonction. Par exemple, les couches convolutionnelles (CNN) utilisent des poids partagés et l'invariance spatiale pour apprendre efficacement des représentations hiérarchiques à partir d'images, de langage naturel et de données temporelles. Les réseaux neuronaux récurrents utilisent la rétropropagation dans le temps pour apprendre à partir de données séquentielles de longueur variable. Les réseaux à mémoire à long terme (*Long Short-Term Memory* LSTM) sont un type de réseau récurrent capable d'apprendre la dépendance d'ordre dans les problèmes de prédiction de séquence. Les réseaux de croyance profonde, les autoencodeurs et d'autres modèles non supervisés génèrent des caractéristiques latentes significatives pour des tâches en aval et modélisent les concepts sous-jacents des distributions en

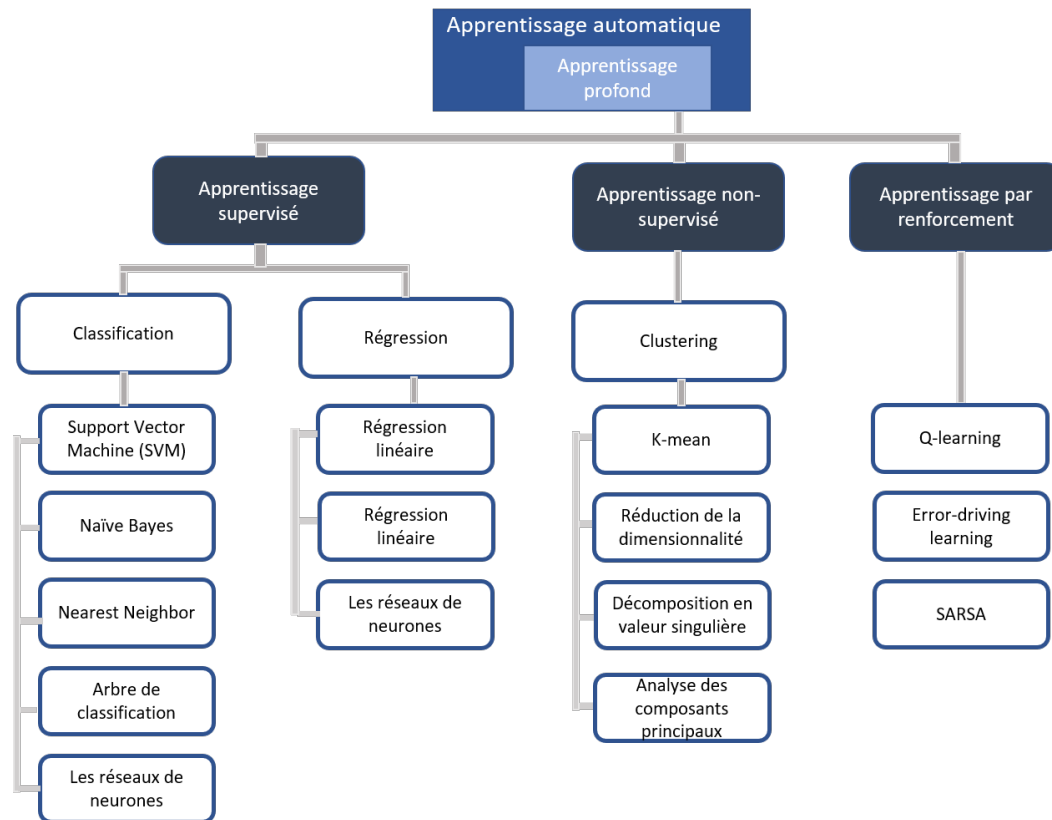


FIGURE 2.10 – Les méthodes d'apprentissage automatique, adaptée de [50]

reconstruisant leurs entrées. En résumé, l'apprentissage profond permet de créer des représentations abstraites structurées des données qui présentent les caractéristiques nécessaires pour résoudre les tâches que le modèle est formé à résoudre comme la regression ou la classification ou reconstruction des données.

2.6.2 La fusion de données par des réseaux neuronaux profonds

Ces dernières années, une progression notable du nombre de recherches associées aux algorithmes de fusion de capteurs par apprentissage profond dans le domaine du véhicule autonome. Dans [30], la fusion des technologies GNSS/INS est proposée par l'intermédiaire des réseaux de neurones. Par la suite, [29] et [166] ont proposé le même principe avec une différence au niveau de la topologie et de l'architecture des réseaux neuronaux mis en œuvre. Ces algorithmes semblent présenter des performances supérieures à celle d'un filtre de Kalman standard au niveau de la précision d'estimation de position. Dans [171], un formalisme de fusion basé sur l'apprentissage profond pour une localisation urbaine est proposé en utilisant le LiDAR et une caméra. Une méthode de fusion en deux étapes est proposée pour la génération et la vérification d'hypothèses à l'aide d'une caméra stéréo et d'un LiDAR afin d'améliorer la détection des véhicules dans [215]. Un système de détection et de suivi de véhicules en

temps réel est proposé pour des scénarios urbains complexes qui fusionnent une caméra, un LiDAR 2D et le contexte routier à partir de la connaissance de la carte routière antérieure en utilisant un CNN et un KF [194].

Afin d’optimiser la sûreté et la fiabilité des systèmes de localisation, certains chercheurs [91, 122] utilisent le KF assisté par les réseaux de neurones pour améliorer l’estimation de l’état. Dans [91], les avantages du filtre de Kalman sont cités, lorsqu’il est utilisé dans le récepteur GNSS comme estimateur de l’état de navigation, car il fournit des solutions optimales si les statistiques de bruit pour la mesure et le système sont complètement connues. En pratique, le bruit varie avec le temps, ce qui entraîne une dégradation des performances. La méthode d’appariement des covariances est une approche adaptative classique pour l’estimation de matrices de covariance du bruit. La technique tente de rendre les erreurs réelles des résidus conformes à leur covariance théorique. Pour résoudre ce problème, les auteurs utilisent un réseau de neurones pour identifier la covariance du bruit de mesure et ils ont prouvé que la précision du positionnement est considérablement améliorée en utilisant cette méthode.

Finalement, les solutions de localisation combinant plusieurs capteurs ont donné des meilleures performances qu’un capteur seul. Toutefois, en utilisant la fusion de données, le risque de défauts logiciels et matériels augmente, en termes de défauts de capteurs et de problèmes de traitement, en raison du nombre croissant de capteurs et des mécanismes de fusion de données sous-jacents. Il est donc nécessaire d’appliquer une stratégie de tolérance aux fautes dans les applications critiques de sûreté de fonctionnement, afin de surmonter ces problèmes et de détecter toute les anomalies, et de garantir des résultats plus fiables en termes de performances des systèmes autonomes.

2.7 Les méthodes de Diagnostic

La surveillance de l’état des processus est aujourd’hui une procédure de plus en plus importante dans de nombreux domaines de recherche (transport, électrique, mécanique, chimique, etc). Dans ces domaines, de nombreuses applications présentent des caractéristiques de plus en plus exigeantes afin de répondre à des critères tel que la sûreté, la disponibilité et la fidélité pour assurer leur fonctionnement efficace. A titre d’exemple, pour le développement des véhicules autonomes dans le domaine du transport, il est indispensable de concevoir une fonction de localisation avec une sûreté infaillible, une disponibilité raisonnable du véhicule et avec un coût réduit des capteurs utilisés. Dans ces applications, les besoins sont de plus en plus importants et doivent être assurés. Le filtre particulaire avec une approche de fusion multi-capteurs, est proposé dans les travaux ([23]), et montre de bons résultats.

Cependant, l’utilisation de caméras avec d’autres capteurs pour augmenter la précision entraînera un coût élevé de calcul pour le système de localisation. Un algorithme de détection

des défauts (FD), basé sur l'EKF pour superviser les sorties du système de localisation, suivi par la méthode CUmulative SUM (CUSUM) pour tester le résidu issu du filtre, est proposé dans [177] pour identifier toute déviation importante inattendue. Les auteurs de [134] proposent une méthode de FD pour la localisation d'un véhicule en zone boisée. Une fusion de données est effectuée en utilisant le GPS, les encodeurs et l'IMU sous un estimateur EKF après des tests d'innovation au carré normalisée (Normalized Innovation Squared (NIS)) pour traiter les mesures GPS. Dans ce cadre, la détection et le diagnostic de défauts (ou anomalies) est une étape déterminante pour limiter les événements tragiques consécutifs à la présence d'un défaut non détecté ou mal estimé, mal localisé voir même encore dont la prédiction de l'évolution est inadéquate [74]. Tout d'abord, on commence par définir le concept d'une anomalie ou d'un défaut.

2.7.1 Diagnostic : Concepts de base et définitions

Dans cette section, nous présentons quelques concepts de base et terminologies dans le domaine du diagnostic.

- **Fonctionnement normal** : un système est en fonctionnement normal lorsque ses états, ses entrées et ses sorties sont très proches de leur valeur nominale (pas de défauts).
- **Défaut** : un défaut est généralement défini comme une déviation d'une variable observée ou d'un paramètre calculé par rapport à sa valeur fixée dans les caractéristiques attendues du processus lui-même, des capteurs, des actionneurs ou de tout autre équipement[75].
- **Erreur** : elle est définie comme l'écart entre une valeur mesurée ou estimée d'une variable et la véritable valeur de la grandeur physique.
- **Défaillance** : une défaillance correspond à un défaut ayant un effet néfaste sur le fonctionnement du système. Ce terme est utilisé lorsqu'un dispositif devient inopérant ou il accomplit difficilement sa fonction.
- **Panne** : une panne est l'inaptitude du système à réaliser sa fonction requise. Elle résulte systématiquement d'une défaillance et elle implique l'arrêt total du système.

L'existence de certains défauts et défaillances peut être totalement évitée. En revanche, ces défauts doivent être tolérés et compensés pour ne pas provoquer de défaillance du système. Ceci peut être réalisé par le principe de "*tolérance aux fautes*". La tolérance aux fautes est la propriété qui permet à un système de continuer à fonctionner avec des performances satisfaisantes malgré la présence d'une ou plusieurs défauts ou, plus grave, la défaillance de certains composants du système. La qualité des performances est directement

proportionnelle à la gravité de la défaillance, où même une petite défaillance peut entraîner une panne totale. Le concept de tolérance aux fautes (FT) peut être considéré comme une assurance de la fiabilité du système par le biais de tests et de diagnostics. Dans [41], les auteurs affirment que la tolérance aux fautes ne tolère pas seulement les fautes causées par la dégradation physique du matériel, les défauts des logiciels ou les perturbations de l'environnement, mais inclut également la capacité de tolérer des fautes de conception qui n'ont pas été détectées à ce jour. À proprement parler, un système est dit tolérant aux fautes uniquement s'il ne nécessite pas d'assistance externe pour sa tolérance aux fautes.

Généralement, le concept général de diagnostic comprend les trois tâches principales suivantes :

- **Détection des défauts** : elle concerne la détection des défauts présents dans un système et éventuellement à l'instant de leur apparition [86]. Elle consiste à concevoir des indicateurs de défauts avec des objectifs majeurs tels que la détection rapide et précise, la sensibilité aux défauts et la robustesse aux diverses incertitudes.

- **Isolation des défauts** : Elle suit souvent la détection des défauts. Sa principale mission est d'isoler correctement les variables défectueuses et de déterminer la cause exacte et la localisation d'un défaut en évaluant les symptômes. Cependant, cela nécessite généralement une connaissance supplémentaire du processus combinée aux variables défectueuses isolées pour trouver la cause fondamentale. Cette connaissance supplémentaire est généralement l'un des principaux problèmes à acquérir pour un processus complexe.

- **Identification des défauts** : elle consiste à identifier les principales informations correspondant au défaut (taille, type ou nature) [86]. Cette analyse est essentielle pour :

-Prédire l'évolution du défaut.

-Fournir des informations utiles pour réaliser une approche tolérante aux défauts.

-Précrire une action de gestion de défauts appropriée.

Par ailleurs, un élément important à prendre en compte dans la détection des défauts est le type du défaut. Les défauts peuvent être classés dans les catégories suivantes en fonction de leur comportement variable dans le temps (voir figure 2.11) :

-Défauts intermittents : un défaut intermittent est un défaut qui se produit et disparaît de façon répétée.

-Défauts naissants : un défaut naissant est un défaut qui se développe progressivement et dont l'amplitude augmente avec le temps.

-Défauts brusques ou soudains : Un défaut brusque est un défaut avec un changement




FIGURE 2.11 – Evolution temporelle des défauts : a) Défaut brusque ou soudain b) Défaut intermittent c) Défaut naissant

brusque sur les variables ce qui peut être une anomalie contextuelle lorsqu'une occurrence de données est anormale dans un contexte spécifique uniquement[27].

Selon les applications, la détection, l'isolation et l'identification de ces différents types de défauts ont des niveaux de complexité différents. Pour la localisation des véhicules autonome avec des technologies à coût faible en utilisant les systèmes GNSS, les défauts soudains sont les plus difficiles à détecter et à caractérisées en raison de leur capacité à apparaître et disparaître soudainement selon le contexte de navigation. Dans ce cadre, de nombreux travaux sont développés dans le domaine du diagnostic par les communautés scientifiques différentes sur des aspects méthodologiques (Traitement de l'information, signal et image). Le point commun de tous ces acteurs est qu'ils développent, mettent en oeuvre des techniques conventionnelles qu'ils ont été bien évaluées au fil des ans. Ces techniques permettent une quantification rigoureuse d'un défaut, qui peut être détecté par l'une des méthodes suivantes : (1) une déviation par rapport à un modèle sous-jacent attendu (méthodes statistiques) ; (2) une valeur métrique anormale (par exemple, la distance euclidienne) dans la mesure de la différence entre la valeur attendue et la valeur prédite (séries temporelles) ; (3) un changement de fréquence mis en évidence dans le domaine de la transformation de Fourier (traitement du signal) ; (4) une erreur de reconstruction entre l'entrée et sa projection sur l'espace des vecteurs propres (l'analyse en composantes principales (ACP ou PCA en anglais pour principal component analysis) - techniques spectrales) ; (5) une fausseté dans le contenu de l'information (théorie de l'information) [46]. Dans la littérature, ces méthodes de diagnostic sont classifiées, en deux familles (voir figure 2.12 :

- Des approches de la redondance matérielle
- Des approches de la redondance analytique

Approches de la redondance matérielle : Elles consistent à mesurer un seul paramètre d'entrée crucial à l'aide de deux capteurs ou plus (généralement trois ou plus), puis l'opération

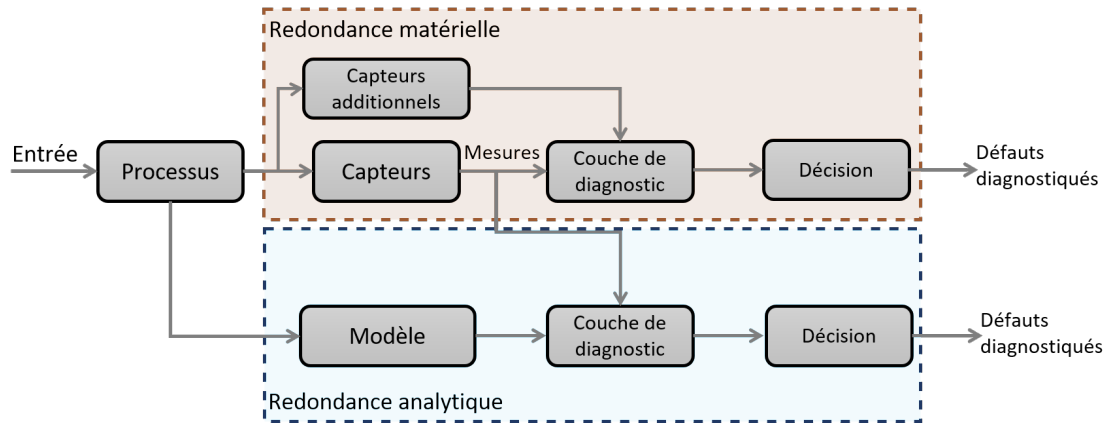


FIGURE 2.12 – Approche analytique et matérielle, adaptée de [52]

de détection est exécutée par le biais d'une supervision de cohérence fournie par les capteurs redondants, et l'isolation du capteur défectueux par un processus de vote majoritaire. Comme avantage, les approches de redondance matérielle sont faciles à mettre en œuvre, et peuvent fournir un haut degré de certitude pour la technique de détection et l'isolation des défauts, connue en anglais sous l'acronyme FDI pour *Fault Detection and Isolation*. Néanmoins, l'utilisation de capteurs redondants n'est pas toujours possible en raison de restrictions de coût et d'espace. En outre, la probabilité d'un défaut est assez élevée car les capteurs redondants travaillent ensemble. En outre, il y a une forte probabilité de présence de défaut(s) car les capteurs redondants travaillent dans le même environnement et sont exposés aux mêmes conditions, ce qui conduit à des défaut(s) dans les mesures.

Approches de la redondance analytique : Le concept de ces approches est la réalisation sur la base des relations fonctionnelles entre les mesures elles-mêmes, fournissant un modèle pour le système. L'approche trouve la relation entre les entrées mesurées en se basant sur un modèle mathématique, et génère des résidus afin de détecter et d'isoler le capteur défectueux. Dans ce cas, le modèle mathématique est créé en utilisant la physique sous-jacente ou déduit des mesures. Les résidus générés sont sous la forme de différences entre les sorties du modèle créé et les mesures réelles reçues, en prenant en compte les techniques choisies pour la détection et l'isolation des défauts qui ne nécessitent pas de capteurs redondants supplémentaires. Après la génération des résidus, une décision est prise par la technique de seuillage pour évaluer les résidus et prendre la décision finale pour la détection et l'isolation. Les approches de redondance analytique peuvent être appliquées en utilisant deux théories différentes :

- Méthodes basées sur des modèles
- Méthodes basées sur données

2.7.2 Génération des résidus par des méthodes basées sur des modèles

L'un des challenges scientifiques important aujourd'hui dans le domaine de localisation des véhicules autonomes est de proposer des solutions pour la détection des défauts dans une situation donnée le plus tôt possible malgré que son effet sur le système peut être très faible et sans conséquence majeure ce qui nous mène à mettre en place des solutions suivi (monitoring) en fonction de son évolution dans une situation donnée.

Dans la littérature, il n'existe que peu de travaux concernant la tolérance aux fautes dans la

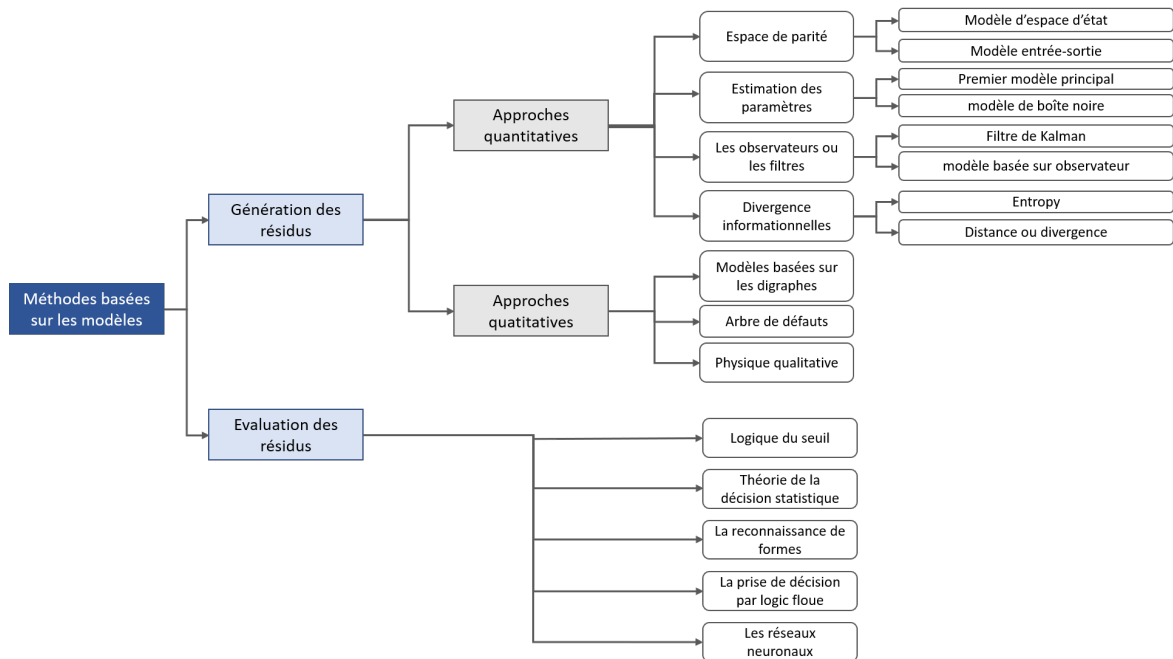


FIGURE 2.13 – Schéma des approches de détection des défauts basées sur les modèles

communauté de la fusion de données multi-capteurs [71]. Les approches basées sur un modèle, également appelées approches de redondance analytique sont généralement les plus étudiées pour éliminer les mesures erronées. Ces approches sont divisées en approches quantitatives et qualitative. Les deux approches sont basées sur un concept commun. Il consiste principalement en deux étapes de fonctionnement : la détection des défauts et la gestion de défauts. Le système de détection des défauts (dans le cas des deux approches) doit idéalement répondre à certaines exigences générales :

- Génération des résidus sensible aux défauts (intermittents, naissants et abrupts).
- Robustesse face aux entrées inconnues (perturbations externes, bruits de mesure et incertitudes du modèle).
- différenciation des défauts des entrées inconnues afin d'éviter les fausses alarmes et les détections manquées.
- Réduction du temps de calculs afin de pouvoir intégrer les algorithmes de FD facilement

dans des systèmes à grande échelle.

Une fois ces conditions réunies, une étape primordiale dans le schéma de FD est activée : l'évaluation des résidus générés d'une façon optimale. Afin d'extraire l'information relative aux défauts et de prendre la décision au sujet de la présence des mesures erronées dans le système, différentes techniques d'analyse sont proposées dans la littérature. On peut citer le seuillage, les réseaux neuronaux et la reconnaissance des formes.

Les méthodes quantitatives pour la génération des résidus

Dans ces méthodes, les résidus sont générés en comparant les mesures réelles avec les valeurs obtenues à partir d'une modélisation mathématique du système. Au cours des deux dernières décennies, de nombreuses méthodes de génération de résidus basées sur des modèles mathématiques ont été développées et peuvent être divisées en quatre groupes :

- Approche basée sur l'espace de parité
- Approche basée sur les observateurs ou les filtres
- Approche basée sur l'estimation des paramètres

Approche basée sur l'espace de parité

Initié par les travaux de Chow et Willesky dans les années 80 [33]. L'approche de parité est basée sur le test "vérification de parité" de la cohérence des équations de parité, la relation qui génère le résidu est appelée une équation de parité, en utilisant les signaux mesurés du processus réel. Ces relations de parité permettent de découpler les résidus de l'état du système et de découpler les résidus entre eux. L'incohérence dans les relations de parité indique la présence d'un défaut (voir figure 2.14). Cette approche peut être appliquée soit à un modèle d'espace d'état dans le domaine temporel [33] ou à un modèle d'entrée-sortie dans le domaine fréquentiel [56, 57], [38].

Récemment, la méthode de la relation de parité a été étendue au diagnostic des défauts pour des modèles non linéaire et complexes tels que la localisation des véhicules autonomes. Dans [125], une méthode basée sur l'espace de parité a été appliquée pour la détection des défauts capteurs, pour une localisation fidèle dans un environnement complexe. Les données des capteurs sont fusionnées et sélectionnés. Ensuite, ils sont combinés dans un ensemble d'équations de parité linéairement indépendantes. Un ensemble de résidus sont générés. Enfin, la présence d'un défaut se manifeste par la croissance d'un sous-ensemble unique de ces résidus.




FIGURE 2.14 – Schéma de l'approche basée sur l'espace de parité, adaptée de [52]

Approche basée sur les observateurs ou les filtres

Le principe de cette approche est de comparer en temps réel la valeur réelle de la sortie du processus et la valeur estimée issue de l'observateur. La structure standard d'un observateur diagnostique linéaire d'ordre complet est présentée à la figure 2.15. Le vecteur de sortie réel S est comparé au vecteur de sortie \hat{S} du modèle nominal et la différence $r = S - \hat{S}$ est réinjectée avec la matrice de gain de retour H . La rétroaction est nécessaire pour compenser les conditions initiales non adaptées et pour stabiliser l'observateur dans le cas d'un système instable. Elle offre également une liberté de conception afin d'atteindre la robustesse, dans le cas idéal en découplant les effets des défauts de l'effet des entrées inconnues, ou pour découpler les effets des défauts les uns des autres dans le but d'isoler les défauts. De la même manière, on peut utiliser des observateurs d'ordre réduit, des filtres de Kalman (dans le cas de mesures bruitées) ou des observateurs non linéaires (dans le cas de processus non linéaires). Un exemple principal qui peut être donné est l'utilisation d'un banc de filtres (filtre de Kalman, filtre particulière...). Chaque filtre est un estimateur d'état qui produit un résidu spécifique en comparant l'estimation à un seuil. Une application de cette méthode peut être trouvée dans [211]. Ces dernières années, le problème de la génération de résidus à l'aide de la théorie

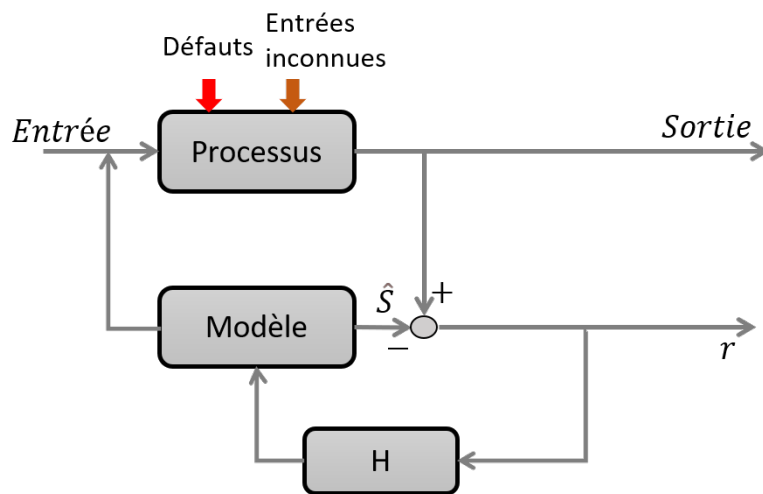


FIGURE 2.15 – Schéma de l'approche basée sur un observateur : Filtre de Kalman, adaptée de [52]

de l'information est soulevé, où, la quantité d'information obtenue à partir d'une observation est plus importante que l'information elle-même. Une description détaillée peut être trouvée dans [5]. Dans le cadre de la théorie de l'information, une large gamme d'outils en forme de divergences ou de distances peuvent être utilisées (information mutuelle, divergence de Kullback Leibler, divergence de Jenson Shannon, divergence de α -Rényi, ...). L'idée est de comparer deux distributions de probabilités afin d'étudier le comportement du système. Les approches basées sur des modèles FDI informationnels ont prouvé leur efficacité pour traiter les mesures erronées des capteurs. Dans cette section, nous présentons quelques divergences informationnelles connues :

La divergence de Kullback-Liebler Après l'entropie de Shanon, Solmon Kullback et Richard Leibler inventent la KLD en 1951 pour comparer deux distributions de probabilité P et Q ([113]).

Elle est également définie comme l'espérance d'un rapport de vraisemblance logarithmique qui joue un rôle essentiel dans la théorie de la détection, où elle peut être écrite comme [182] :

$$KLD(P||Q) = E_p \left(\frac{p(x)}{q(x)} \right) \quad (2.18)$$

Dans le cas où P et Q sont deux distributions gaussiennes avec des moyennes μ_p et μ_q et des matrices de covariance Σ_p et Σ_q respectivement, le KLD s'écrit comme :

$$KLD(P||Q) = \frac{1}{2} \left[\text{trace}(\Sigma_q^{-1}\Sigma_p) + \log \left| \frac{\Sigma_q}{\Sigma_p} \right| - M + (\mu_p - \mu_q)^T \Sigma_q^{-1} (\mu_p - \mu_q) \right] \quad (2.19)$$

Où M est la dimension des distributions.

D'après l'équation 2.19, la KLD peut être interprété comme la somme de deux tests : 1) le test des moyennes représenté par $(\mu_p - \mu_q)^T \Sigma_q^{-1} (\mu_p - \mu_q)$. Ce test est assimilé à la distance de Mahalanobis. 2) le test sur les matrices de covariance illustré par $\text{trace}(\Sigma_q^{-1}\Sigma_p) + \log \left| \frac{\Sigma_q}{\Sigma_p} \right| - M$. Ce test a la forme de la divergence de Bregman et inclut l'information mutuelle entre deux distributions gaussiennes représentées par $\log \left| \frac{\Sigma_q}{\Sigma_p} \right|$.

La divergence de Bahattacharya la divergence de Bhattacharyya est une métrique qui mesure la similarité entre deux distributions discrètes ou continues. La BD entre deux distributions de probabilité P et Q est s'écrit comme suit [12] :

$$BD(P||Q) = -\log BC(P||Q) \quad (2.20)$$

Où \log représente le logarithme naturel, et BC est le coefficient de Bhattacharyya décrit comme :

$$BC(P||Q) = \int \sqrt{p(x)} \cdot \sqrt{q(x)} dx \quad ; \text{continous case} \quad (2.21)$$

$$BC(P||Q) = \sum \sqrt{p(x)} \cdot \sqrt{q(x)} dx; \text{ ; cas discret} \quad (2.22)$$

Le BC est lié à la distance de Hellinger au carré par la relation suivante :

$$\begin{aligned} Hell^2(P||Q) &= \frac{1}{2} \int \left(\sqrt{p(x)} - \sqrt{q(x)} \right)^2 dx \\ &= \frac{1}{2} \left[\int p(x) dx + \int q(x) dx - 2 \int \sqrt{p(x)} \cdot \sqrt{q(x)} dx \right] \\ &= 1 - BC(P||Q) \end{aligned} \quad (2.23)$$

L'un des avantages principales de la BD est qu'il n'est pas nécessaire de spécifier une distribution de référence, ce qui n'est pas le cas pour la KLD.

La divergence de α -Rényi Pour deux distributions de probabilités P et Q , la divergence de α -Rényi (α -RD) entre P et Q est non décroissante en fonction de son ordre α . De plus, cette divergence est continue sur l'ensemble des α pour lequel elle est finie. Elle peut s'écrire comme suit :

$$RD_\alpha(P||Q) = \frac{1}{\alpha - 1} \ln \int P^\alpha(x) Q^{1-\alpha}(x) d(x) \quad (2.24)$$

Où $\alpha \in R^+ \setminus \{1\}$ ([190]).

Lorsque α s'approche de zéro, l'entropie de Rényi pondère toutes les possibilités de manière plus égale, quelles que soient leurs dissemblances. Dans la limite $\alpha \rightarrow 0$, la α -RD glisse vers la probabilité logarithmique négative sous Q que P soit non nul ([153]) :

$$RD_0(P||Q) = \lim_{\alpha \rightarrow 0} RD_\alpha(P||Q) = -\log Q(p > 0) \quad (2.25)$$

Si les deux distributions ont le même support, alors

$$\lim_{\alpha \rightarrow 0} RD_\alpha(P||Q) = 0$$

Cette divergence n'est symétrique que lorsque $\alpha = 0.5$, ce qui donne les BC et BD vus dans l'équation 2.20 ([12]) :

$$RD_{\frac{1}{2}}(P||Q) = -2 \log \int \sqrt{P(x)} \cdot \sqrt{Q(x)} dx = 2BD(P||Q) \quad (2.26)$$

Nous retrouvons l'entropie de relativité dans la limite de $\alpha \rightarrow 1$, où la relation entre α -RD et le KLD apparaît en utilisant le théorème de Hospital ([11]). Cette relation peut être représentée par l'équation suivante :

$$RD_1(P||Q) = \lim_{\alpha \rightarrow 1} (RD_\alpha(P||Q)) = KLD(P||Q) \quad (2.27)$$

Notez que la $RD_\alpha(P||Q)$ est non décroissante en α sur $[0, 1] \cup \{\alpha \in [1, \infty] | RD_\alpha < \infty\}$.

La $RD_\alpha(P||Q)$ est symétrique pour $0 < \alpha < 1$ où il peut être écrit comme $RD_\alpha(P||Q) = \frac{\alpha}{\alpha-1} RD_{1-\alpha}(Q||P)$, et pour $\alpha = 2$ la divergence devient liée au χ^2 ([15]).

Dans ces travaux, on cherche à comparer les distributions *a priori* et *a posteriori* au sein du filtre informationnel. On propose d'utiliser la divergence α -Rényi pour la conception du résidu, pour une valeur du paramètre α qui tend vers 1 elle correspond à la divergence de Kullback-Leibler et α égale à 0.5 à la divergence de Bhattacharyya.

Approche basée sur l'estimation des paramètres

Cette approche repose sur l'hypothèse que les défauts se retrouvent dans les paramètres physiques du système tels que la friction, la masse, la viscosité, la capacité, l'inductance, etc. L'idée de base de la détection est que les paramètres du processus réel sont estimés en ligne de manière répétée en utilisant des méthodes d'estimation des paramètres bien connues et les résultats sont comparés aux paramètres du modèle de référence obtenus initialement dans des conditions sans défaut. Tout écart important indique un changement dans le processus et peut être interprété comme un défaut. Le travail de base dans le développement et l'application de cette approche a été effectué par Iserman et ses collègues [85]. D'autres contributions importantes ont été faites par la procédure d'estimation des paramètres qui comprend deux étapes principales : l'estimation des paramètres mathématiques, p , et leur transformation en paramètres physiques, q , comme le montre la figure 2.16. La méthode peut également être appliquée à des processus non linéaires à condition que le modèle soit linéaire dans les paramètres du processus. L'approche la plus courante de l'estimation des paramètres est celle de la méthode des moindres carrés.

Les méthodes qualitatives de génération des résidus

Dans le cas où les équations fonctionnelles mathématiques ne sont pas accessibles, et que les relations des fonctions qualitatives centrées sur différentes unités peuvent être identifiées, des approches qualitatives basées sur des modèles pour la détection des défauts peuvent être utilisées. Dans les approches qualitatives, la génération des résidus est basée sur une comparaison du comportement prédit avec le comportement réel. Cette approche utilise des informations non quantitatives pour décrire la structure et le fonctionnement du système. Le résultat de la comparaison permet non seulement de détecter si le système est défaillant, mais aussi d'identifier la source de la faute. En outre, les résidus dans les approches qualitatives basées sur les modèles peuvent être obtenus en utilisant :

- Les modèles basés sur les digraphes

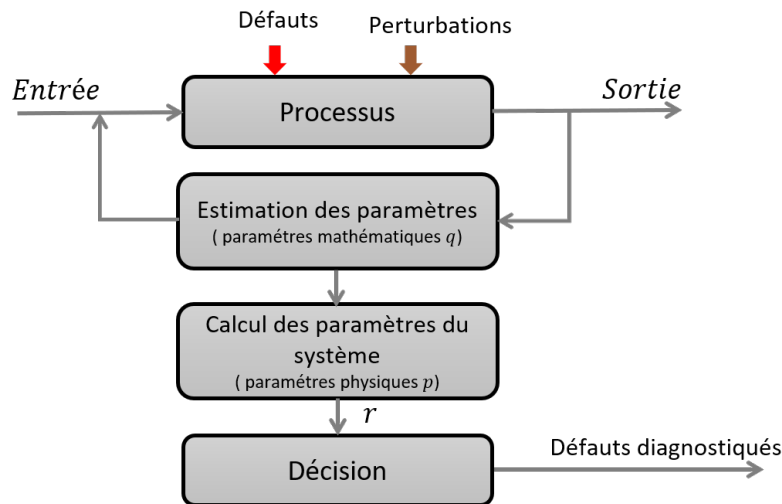


FIGURE 2.16 – Schéma de l'approche basée sur l'estimation des paramètres, adaptée de [52]

- L'arbre de défauts
- La physique qualitative

Les modèles basés sur les digraphes

Les relations ou modèles de cause à effet peuvent être représentés sous la forme de digraphes signés (SDG). Un digraphe est un graphe avec des arcs dirigés entre les nœuds et SDG est un graphe dans lequel les arcs dirigés sont associés à un signe positif ou négatif. Le nœud représente l'événement ou la variable de processus (ou une autre variable continue). Les arcs dirigés mènent des nœuds de "cause" aux nœuds d'"effet". Les SDG constituent un moyen très efficace de représenter graphiquement des modèles qualitatifs et ont été la forme la plus largement utilisée de connaissance causale pour le diagnostic des défauts de processus. Les auteurs dans [83] ont été les premiers à utiliser les SDG pour le diagnostic des défauts. À partir de SDG, ils dérivent ce que l'on appelle un graphe cause-effet (graphe CE). Dans [108], les auteurs ont utilisé la dynamique partielle du système, des informations statistiques sur les défauts des équipements et des digraphes pour représenter le réseau de propagation des anomalies afin d'identifier la localisation des défauts. Des méthodes basées sur des règles utilisant SDG ont été utilisées pour le diagnostic des défauts par Kramer et Palowitch [110].

L'arbre de défauts

Les arbres de défauts ou défauts sont généralement utilisés pour évaluer la fiabilité et la sécurité des systèmes, ils ont été largement utilisés dans plusieurs domaines tel que les procédés chimiques, l'ingénierie mécanique, la robotique [196, 214]. L'analyse par arbre de défauts a été développée à l'origine dans les laboratoires de Bell Telephone en 1961. L'analyse

par arbre de défauts est une analyse des défauts déductive descendante. Elle contient deux types de nœuds : les événements et les portes. Les événements sont définis comme un défaut d'un sous-système jusqu'à un composant individuel, et les portes représentent la façon dont les défauts se propagent dans le système. L'établissement de l'arbre de défauts peut aider à trouver toutes les combinaisons possibles de causes et de probabilités de défaillances. Ensuite, les mesures correspondantes peuvent être prises pour prévenir les défauts du système. La capacité d'analyse des arbres de défauts a été validée dans l'évaluation des risques et l'analyse de la fiabilité dans de nombreuses applications [98, 188].

Cependant, ces techniques présentent certaines limitations dans le cas où les données présentant des défauts ou le comportement sont inconnus. Dans les systèmes complexes comme le véhicule autonome les incertitudes, les perturbations peuvent être inconnus à cause de l'environnement principalement. Dans ce cas, le diagnostic des défauts à l'aide d'un arbre de défauts est peu évident, et conduit à une faible fidélité dans la détection des défauts particulièrement pour le traitement des défauts soudains.

La physique qualitative

La connaissance qualitative de la physique dans le diagnostic des défauts a été représentée principalement de deux manières. La première approche consiste à dériver équations qualitatives à partir des équations différentielles appelées équations de confluence. Des travaux considérables ont été réalisés dans ce domaine de la modélisation qualitative des systèmes et de la représentation des connaissances causales, notamment [37, 173] et [87]. L'autre approche de la physique qualitative consiste à dériver un comportement qualitatif à partir des équations différentielles ordinaires (ODE). Ces comportements qualitatifs peuvent être utilisés pour différents défauts comme source de connaissances. Dans [158], les chercheurs examinent des approximations linéaires par morceaux d'équations différentielles non linéaires en utilisant l'utilisation d'un raisonneur mathématique qualitatif pour déduire les propriétés qualitatives du système. Dans [112], les travaux sont basées sur la prédiction du comportement qualitatif en utilisant des équations différentielles qualitatives (QDE) qui sont une abstraction des ODE qui représentent l'état du système. En termes d'applications des modèles qualitatifs dans le diagnostic de défauts, les approches les plus populaires sont la simulation qualitative (QSIM) et la théorie qualitative des processus (QPT). Parmi les exemples de travaux de recherche réalisés sur la QSIM, notamment [149] et [97].

2.7.3 Génération des résidus par des méthodes basées sur les données

Depuis quelques années, le développement des technologies et techniques offre la possibilité de stocker et traiter des données en masse. Dans les processus de supervision de la

performance du système, cette possibilité est une réelle opportunité de stocker des données décrivant bien un processus dans toutes ses conditions de fonctionnement. Les méthodes guidées par les données modélisent les processus en utilisant la relation, les classes de défauts et les types données. Ces méthodes réduisent les dimensions des données en se basant sur des approches statistiques multivariées, contrairement aux méthodes basées sur les modèles, qui apprennent le comportement des défauts en utilisant l'ensemble des données. Ainsi, elle peut convertir des données de haute dimension en une dimension inférieure uniquement.

Par conséquent, cette stratégie est utile pour les systèmes d'ingénierie modernes à grande échelle. Ces approches peuvent être considérées comme des approches de type "boîte noire" car elles n'ont pas besoin de modèles de système ou de connaissances spécifiques au système pour mettre en place un processus de diagnostic. Ils utilisent une variété de techniques d'exploration de données pour extraire et déterminer les caractéristiques des défauts à partir d'une quantité massive de données d'exploitation acquises. La figure 2.17 présente les approches basées sur les données. Elle peuvent être classées en deux catégories : des approches pour l'extraction des caractéristiques et des approches pour l'analyse des caractéristiques [101] :

- Extraction de caractéristiques : Généralement utilisée dans le domaines de l'apprentissage automatique, l'extraction de caractéristiques utilise un ensemble de données mesurées initial, réduit leur dimensions et génère par la suite des données déduites appelées caractéristiques. Elles consistent à fournir des informations pertinentes et non redondantes sur le résidu, qui pourraient être utiles pour détecter, isoler ou identifier des défauts. Dans un processus de diagnostic de défauts, les caractéristiques doivent être extraites de la grande quantité d'informations caractérisant le système. Selon l'application, on peut extraire des informations quantitatives ou qualitative.
- Analyse des caractéristiques : Elle permet l'évaluation des informations sélectionnées pour conduire à la prise de décision. Selon l'objectif si c'est la détection, l'isolation ou l'identification, cette évaluation peut prendre différentes formes (estimation, test de seuil, classification, ...).

Les méthodes d'extraction des informations quantitatives peuvent être classées en deux catégories principales : les méthodes non statistiques et les méthodes statistiques. Le principe des approches statistiques est d'utiliser des paramètres statistiques, tels que les moments statistiques ou d'autres informations comportementales pour procéder à l'analyse basée sur les distributions probabilistes sous-jacentes connues ou inconnues. Les méthodes non statistiques sont basées sur les données sans utiliser d'informations statistiques. Elles sont divisées en deux classes : L'apprentissage automatique et le traitement du signal.

D'autre part, l'approche qualitative basée sur les données qui approchent et caractérisent les informations sur les défauts. Ces approches sont classées en deux catégories : Le système

expert et l'analyse qualitative des tendances. Dans les sections suivantes, une présentation détaillée des approches basées sur les données sera proposée.

Les méthodes quantitatives

Les approches statistiques Les approches statistiques sont basées sur l'analyse des propriétés statistiques des données telles que la loi de distribution, ainsi que d'autres critères. Le modèle statistique est ajusté sur la base des données qui représentent l'état de fonctionnement correct du système. Ensuite, les propriétés statistique des nouvelles observations sont comparées à celles du modèle statistique ajusté pour déterminer l'état du système (normal ou anormal). Dans la littérature, il existe deux méthodes pour ajuster les données dans un modèle statistique : l'approche paramétrique et l'approche non-paramétrique. Les approches paramétriques sont basées sur les propriétés statistiques connues généralement sous la forme d'une distribution connue, comme la loi normale, la loi exponentielle, la loi gamma et d'autre formes des données. Les approches paramétriques les plus utilisées sont basées sur le test d'hypothèse, l'estimation du maximum de vraisemblance, la théorie des valeurs extrêmes, l'analyse de la variance, etc. Les approches non paramétriques sont proposées pour traiter les cas où la distribution de probabilité sous-jacente n'est pas connue et les données ne peuvent pas être modélisées avec la distribution standard. Les techniques non-paramétriques les plus populaires sont l'estimation de la densité par fenêtre de Parzen, les approches basées sur l'histogramme, les approches du plus proche voisin et le test de Wilcoxon-Mann-Whitney.

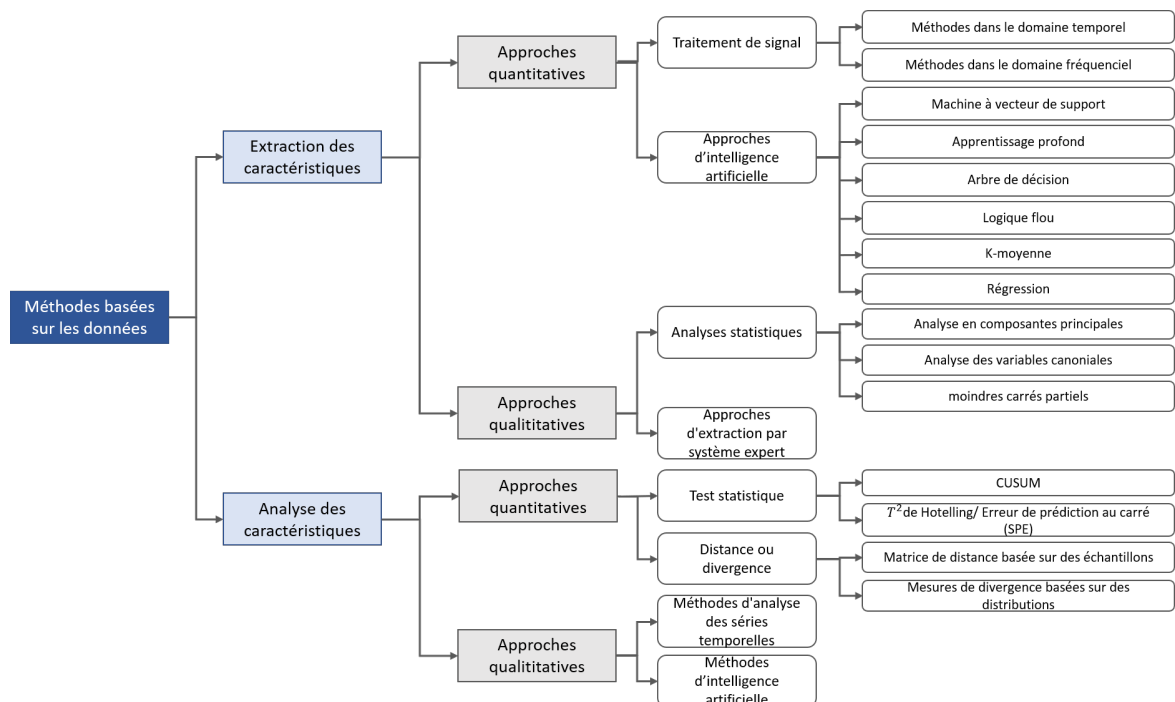


FIGURE 2.17 – Schéma des approches de détection des défauts basées sur les données

Les approches non statistiques

Les méthodes d'intelligence artificielle Les méthodes d'intelligence artificielle sont utilisées pour entraîner différents algorithmes d'apprentissage sur les données collectées afin d'identifier automatiquement et intelligemment des défauts complexes et de diagnostiquer les anomalies. Parmi les techniques d'intelligence artificielle, on peut citer les approches d'apprentissage automatique comme l'arbre de décision, la logique floue, la machine à vecteur de support (SVM), les ANN, et la tendance actuelle l'apprentissage profond ; les réseaux neuronaux profond et leur variétés. C'est un concept qui fait référence aux modèles ou techniques de développement qui accèdent à de grandes quantités de données afin d'en extraire des informations utiles qui peuvent être utilisées pour fournir et soutenir des décisions. Ces techniques ont la capacité de générer une sortie désirée à partir d'entrées inconnues. Dans la prochaine section une explication du concept de détection de défauts par apprentissage profond est présentée.

Les méthodes de détection par apprentissage profond

Toutes les techniques conventionnelles nécessitent principalement une bonne connaissance de ce que l'on appelle la "vérité de terrain", afin de dériver une mesure bien quantifiable de l'anomalie. Malheureusement, dans de nombreux scénarios du monde réel où les modèles de données sont extrêmement variables dans le temps, la complexité de ces techniques n'est pas récompensée par des performances satisfaisantes. Il est donc nécessaire d'introduire des techniques basées sur un nombre important des données qui, au prix d'une formalisation moins stricte, permettent des ajustements plus flexibles et par conséquent d'obtenir des résultats plus précis.

Actuellement, les méthodes basées sur les données, comme l'apprentissage automatique et l'apprentissage profond, ont attiré davantage l'attention et se sont avérées de plus en plus efficaces. Ces techniques font généralement référence à des méthodes basées sur l'apprentissage où l'absence d'un modèle mathématique sous-jacent robuste est compensée par la disponibilité de grandes quantités de données, à partir desquelles on peut "apprendre" des informations utiles. Par conséquent, Hodge et Austin [80] discernent trois approches fondamentales du problème de la détection des valeurs aberrantes, à savoir :

- Supervisée : la normalité et l'anormalité sont toutes deux modélisées qui nécessitent des données étiquetées pour chacune des catégories.
- Non supervisée : identification des anomalies sans connaissance préalable des données.
- Semi-supervisée : seule la normalité est modélisée ; les anomalies sont identifiées par le fait qu'elles ne se situent pas en dessous du seuil fixé.

Les trois approches présentent un certain chevauchement avec les principales catégories de l'apprentissage automatique car elles partagent des caractéristiques communes.

Dans la littérature, Différentes approches ont été proposées pour la détection et l'isolation des défauts. Dans [123], ils proposent une méthode d'apprentissage profond avec plusieurs modules de mémoire à long terme (multi-LSTM) pour prédire la position du véhicule basé sur un modèle de mixture gaussienne (GMM) et de la divergence de Kullback-Leibler (KLD). Dans [176], un RNN multicouche est appliqué dans l'algorithme de RAIM (Receiver Autonomous Integrity Monitoring) pour améliorer le taux de détection des petits défauts et réduire le délai d'alarme des systèmes GNSS.

Comparaison entre les méthodes basées sur des modèles et les méthodes basées sur données

Les avantages des méthodes basées sur des modèles :

-Ils ont l'avantage de résoudre le problème d'information incomplète. Aussi, ils peuvent prendre en compte différents types d'informations de diagnostic que les méthodes basées sur les données ne peuvent pas utiliser. En outre, elles peuvent appliquer les connaissances du domaine et l'expérience d'experts au processus FDI en particulier lorsque les l'information n'est pas suffisante.

- Ils peuvent également être généralisés. Fondamentalement, ils peuvent extrapoler au-delà des données d'apprentissage parce que les modèles sont créés sur la base des principes. Ils peuvent fonctionner correctement à n'importe quel niveau de de gravité des défauts dans un large éventail de conditions de fonctionnement.

- Puisque la signification physique de l'ensemble des processus FDI est évidente, ils sont compréhensibles. Les techniciens peuvent comprendre les raisons ou les mécanismes des résultats. Lorsque les données de surveillance changent en raison d'une dégradation des performances, de la maintenance et du remplacement des composants, les méthodes basées sur les modèles peuvent encore fonctionner en ajustant les paramètres paramètres du modèle.

- Un énorme volume de données erronées étiquetées n'est pas nécessaire. La connaissance du domaine basée sur une compréhension profonde des systèmes peut être utilisée pour obtenir les relations qualitatives et même quantitatives entre les fautes et les symptômes sans données entachées par des défauts étiquetées [152].

Les avantages des méthodes basées sur les données :

-Une compréhension approfondie des relations entre les défauts et les paramètres du système n'est pas nécessaire. Puisque les modèles sont automatiquement appris à partir des données, ils n'ont pas besoin de modèles physiques. Ainsi, la mise en œuvre des méthodes basées sur les données est facile.

- Elles sont avantageuses pour résoudre le problème de l'incertitude d'informations incertaines. Les incertitudes peuvent être décrites par l'expérience des experts, les relations entre les défauts et les symptômes, des modèles physiques/de régression et des mesures utilisant

des algorithmes comme la logique floue.

- En général, la précision de leur détection et leur diagnostic des défauts est plus élevée que celle des méthodes basées sur les modèles. En outre, leur sensibilité aux changements de modèles de données de surveillance est élevée.
- En cas d'absence de variables cruciales, elles peuvent encore fonctionner. Parce que les modèles de mesure de variables limitées peuvent être distingués pour l'isolation des défauts.
- Ils peuvent utiliser l'intelligence artificielle comme une stratégie prometteuse. La plupart des algorithmes algorithmes d'intelligence artificielle sont source ouverte avec une riche d'informations documentées [95, 152].

Les inconvénients des méthodes basées sur des modèles :

- Une compréhension approfondie des relations de cause à effet entre défauts et les paramètres du système est nécessaire. C'est ainsi que la plupart des experts trouvent que l'application des méthodes basées sur les modèles préalables difficile.
- En général, la précision des méthodes basées sur les données est plus élevée que celle des méthodes basées sur les modèles. En effet, la précision des modèles physiques est généralement inférieure à celle des modèles basés sur les données.
- Si les capteurs sont installés d'une manière incorrecte, des ajustements complets sont toujours nécessaires. En général, les réglages doivent être effectués par un expert pour modifier les équations et les paramètres [95].

Les inconvénients des méthodes basées sur des données :

- L'entraînement des modèles d'apprentissage pour la détection des défauts nécessite un énorme volume de données avec des défauts étiquetés. Cependant, l'obtention de données avec des défauts est coûteuse. Etant donné qu'en pratique, il est inconcevable de réaliser autant de défauts dans un système réel.
- Les modèles d'apprentissage profond sont conçus à partir d'un ensemble de données d'entraînement. Ils ne sont pas en mesure d'estimer au-delà de la plage de données d'entraînement. La plupart des défauts constituent un large intervalle de niveaux de gravité. En règle générale, le même défaut peut avoir différents niveaux de gravité. Dans ce cas, la détection du défaut est plus complexe pour le modèle, qui sont basé sur des données d'un certain niveau de gravité. Par conséquent, la performance des modèles n'est pas garantie dans les applications réelles [152].
- L'explicabilité des modèles d'apprentissage profond constitue un véritable défi scientifique, qui met évidence le besoin d'explication et le doute sur leur efficacité. C'est un phénomène appelé « boîte noire » (« black box » en anglais), dans le sens où l'on peut juger la qualité et la quantité des données qui entrent dans le réseau de neurones et des résultats qui en sortent, mais sans savoir les raisons ou les mécanismes qui ont abouti à ces résultats, qui sont essentiels pour prendre les décisions.

2.7.4 Les méthodes d'évaluation des résidus et prise de décision

Après la génération du résidu, la deuxième étape d'une procédure de détection des défauts consiste à évaluer le résidu. L'évaluation robuste de résidu est un paramètre clé pour déterminer la faisabilité de l'algorithme de détection de défauts. Généralement, les changements dans le résidu sont significative indiquant l'apparition des défauts. Dans une situation idéale, le résidu doit être affecté uniquement par les défauts. Cela signifie que le résidu devrait s'écarter de zéro uniquement lorsqu'il y a un défaut. Cependant, une telle situation idéale se produit rarement dans la pratique et le résidu est influencé par les perturbations du processus, les bruits de mesure et les incertitudes du modèle. Ces facteurs rendent le résidu non nul même dans le cas sans défaut. Si l'on ne tient pas compte de ces facteurs lors de la conception, le schéma FD peut générer de fausses alarmes. Afin de détecter la présence d'un défauts, la fixation d'une limite est crucial. La figure 2.18 montre une représentation graphique de génération et d'évaluation de résidu, un résidu $r(t)$ évalué est comparé à une limite, appelée "seuil" (" th "), relative aux entrées inconnues et aux incertitudes du modèle. La présence d'un défaut est déduite si le premier dépasse le second :

$$\begin{cases} r(t) < th & \text{absence de défaut} \\ r(t) \geq th & \text{présence de défaut} \end{cases} \quad (2.28)$$

La sélection du seuil approprié est une tâche très critique en FD. Un seuil trop élevé peut entraîner une détection manquée, ce qui signifie qu'un ensemble de défauts peut rester non détecté. De même, la sélection d'un seuil trop bas peut conduire à de fausses alarmes. Dans ce cas, le système de détection indique un défaut, mais en réalité, il n'y a pas de défaut dans le système. Le seuil est généralement considéré comme une limite de tolérance pour les entrées inconnues et les incertitudes du modèle. Pour cette raison, la manière d'évaluer les entrées inconnues joue un rôle important dans l'évaluation de résidus et la détermination des seuils. Dans la littérature, plusieurs approches sont utilisées pour concevoir un seuil, par exemple par la logique du seuil, la théorie de décision par les tests statistiques, réseaux de neurones, la reconnaissance des formes, la logique floue ou les seuils adaptatifs. Généralement, elles sont classées en deux groupes : seuil constant et seuil variable. Les seuils constants sont conçus en considérant la limite supérieure des entrées inconnues et des incertitudes admissibles pour diminuer au maximum une fausse alarme. Contrairement aux seuils constants, les seuils variables varient en fonction des valeurs instantanées de l'entrée du processus et de certains paramètres du système. Il s'agit notamment du seuil dynamique et le seuil adaptatif. Dans la littérature, les tests statistiques sont les plus utilisées pour la prise de décision et plus particulièrement les méthodes de seuillage optimisées. Ces méthodes sont généralement basées

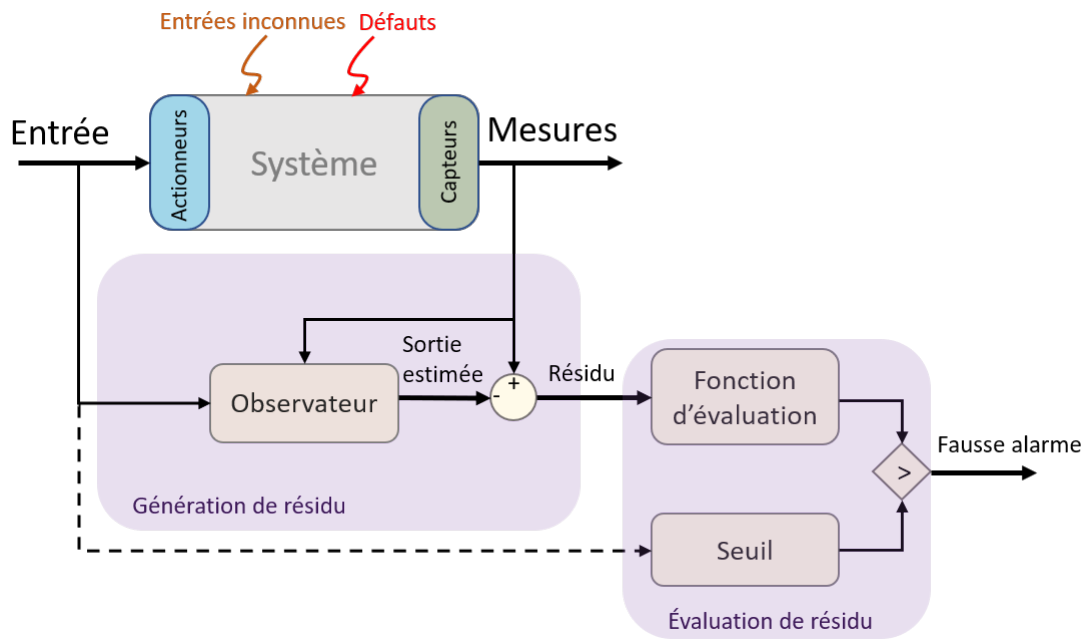


FIGURE 2.18 – Schéma du principe d'évaluation des résidus

sur deux hypothèses H_i :

- H_0 qui représente l'hypothèse dans le cas d'absence de défaut(s).

- H_1 est l'hypothèse en cas de présence de défaut(s).

En effet, ces deux hypothèses aboutissent à deux décisions u_i :

- u_0 est la décision qui correspond à une absence de défaut.

- u_1 est la décision qui correspond à une présence de défaut.

Le tableau 2.5 présente les probabilités associées aux différentes décisions qui peuvent être prises par le système de détection, en considérant que les hypothèses vraies :

On peut définir ainsi :

Hypothèse \ Décision	Décision u_0	Décision u_1
	H_0 vrai (pas de défaut)	bonne décision
H_1 vraie (défaut)	détection manquée	bonne décision

TABLE 2.5 – Situations de décision pour un test statistique entre deux hypothèses

La probabilité d'absence de défaut(s) P_0 : c'est la probabilité de choisir H_0 sachant que H_0 est vraie :

$$P_0 = p(u_0 = H_0) \quad (2.29)$$

— La probabilité de détection P_D : c'est la probabilité de choisir H_1 sachant que H_1 est vraie :

$$P_D = p(u_1 = H_1) \quad (2.30)$$

— La probabilité de fausse alarme P_{fa} : c'est la probabilité de choisir H_1 sachant que H_0 est vraie :

$$P_{fa} = p(u_1 = H_0) \quad (2.31)$$

- La probabilité de détection manquée P_{mD} : c'est la probabilité de choisir H_0 sachant que H_1 est vraie :

$$P_{mD} = p(u_0 = H_1) = 1 - P_D \quad (2.32)$$

Selon la figure 2.19, les probabilités peuvent être calculées de la manière suivante :

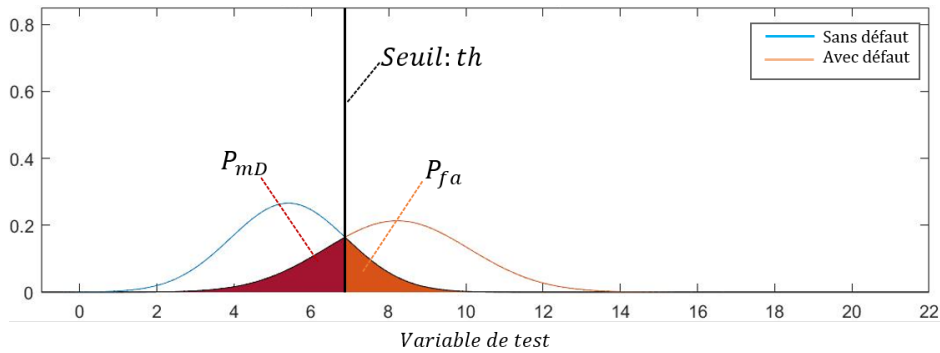


FIGURE 2.19 – Modélisation des probabilités de fausse alarme et des détections manquées

$$P_{fa} = \int_{th}^{\infty} p(x/H_0) dx \quad (2.33)$$

$$P_D = \int_{th}^{\infty} p(x/H_1) dx \quad (2.34)$$

$$P_{mD} = \int_0^{th} p(x/H_1) dx \quad (2.35)$$

Où $p(x = H_0)$ et $p(x = H_1)$ sont les densités de probabilités de la variable test x suivant respectivement les hypothèses H_0 et H_1 .

Dans ce qui suit, nous avons énuméré les tests statistiques qui sont largement utilisés.

Test de Student Ce test statistique vérifie que le signal suit bien une distribution gaussienne, ce qui conditionne un seuillage automatique fournit par la table de Student pour un niveau de confiance désiré (95% par exemple). Si ce seuil est franchi, la décision est H_1 .

Critère de Bayes Dans cette section, on étudie l'approche Bayésienne aux problèmes de décision, qui est basée sur la connaissance, pour chaque hypothèse H_i , de la probabilité *a priori* pour que cette hypothèse se réalise, et qui associe, à chaque comportement possible du système de décision, un coût (équivalent à une pénalisation ou une récompense) :

$$C_{ij} = \text{coût de décider } H_i \text{ quand } H_j \text{ est vrai}$$

A partir de l'équation 2.36, on peut classifier x observation selon l'hypothèse H_0 et H_1 :

$$p(H_1/x) \underset{H_0}{\overset{H_1}{\geq}} p(H_0/x) \quad (2.36)$$

On peut interpréter l'équation 2.36 comme suit :

- Si $p(H_1 = x) > p(H_0 = x)$, alors H_1 est choisie.
- Si $p(H_1 = x) < p(H_0 = x)$, alors H_0 est choisie.

Selon le critère de Bayes, on obtient :

$$\frac{p(x/H_1)p(H_1)}{p(x)} \underset{H_0}{\overset{H_1}{\geq}} \frac{p(x/H_0)p(H_0)}{p(x)} \quad (2.37)$$

Ce qui conduit à un rapport de vraisemblance (*Likelihood ratio test* Λ) suivant :

$$\Lambda = \frac{p(x/H_1)}{p(x/H_0)} \underset{H_0}{\overset{H_1}{\geq}} \frac{p(H_0)}{p(H_1)} \quad (2.38)$$

Critère de Neyman-Pearson

Pour appliquer le test de Bayes, c'est-à-dire, le coût moyen d'une décision u_i , il faut connaître les probabilités *a priori*, qui déterminent la valeur du seuil auquel le rapport de vraisemblance est comparé. Pour beaucoup d'applications, ces valeurs ne sont pas connues, et on ne peut pas, en conséquence, appliquer l'approche Bayésienne, où encore, même si elles sont connues, le critère ajusté au problème n'est pas obtenu par des considérations de ce qui se passe pour tout l'ensemble de situations possibles. Les tests de Neyman-Pearson constituent, dans ces cas, une approche alternative.

Tests minimaux

Les tests minimax sont une autre façon de résoudre des problèmes de décision quand on ne connaît pas les probabilités *a priori*, et correspondent à choisir le test qui a la meilleure performance dans le cas le plus défavorable.

La courbe ROC

Les courbes *ROC* (Receiver Operating Characteristic) [208] présentée sur la figure 2.20 est une manière de fixer le seuil expérimentalement. C'est un graphique qui trace les taux

de vrais positifs (probabilité de détection) en fonction des faux positifs (probabilité de fausse alarme). Cette courbe permet la comparaison de tests de diagnostic effectués sur un même jeu de données. Le seuil optimal est représenté par le minimum de la distance d , au point $(0, 1)$ où la sensibilité (S_N) et la spécificité (S_P) sont respectivement de 100% et 100% en ce point idéal. Le taux de faux positifs est égal à $(1 - \text{spécificité})$, comme un algorithme qui donne un faux positif de 100% a une spécificité de 0%.

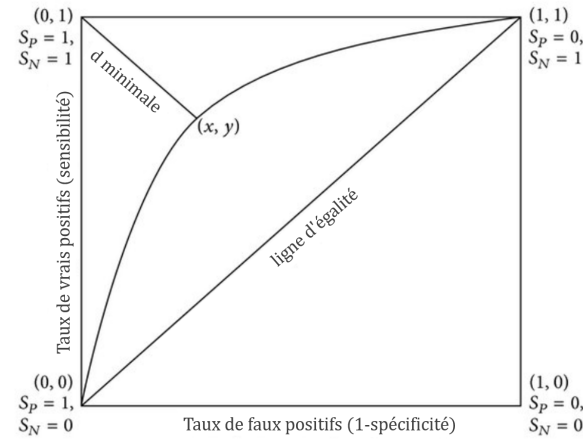


FIGURE 2.20 – Choix du seuil de détection par courbe ROC

Critère d'optimisation informationnel

Dans la théorie Bayésienne, le choix du seuil repose sur la minimisation du risque de Bayes. Dans ce problème d'optimisation, les coûts sont supposés connus *a priori* et constants. Dans certaines applications, il est intéressant de traiter le problème d'optimisation du point de vue quantité d'information plutôt que du point de vue de l'information elle-même. En se basant sur la figure, l'objectif est de minimiser l'ambiguïté entre hypothèse vraie et décision prise. Dans la littérature, plusieurs critères ont été proposés notamment le critère de Kullback Libler, Bahattacharya et α -Rényi.

Critère de Kullback Liebler En se basant sur le théorème de Bayes, le problème d'optimisation du seuil peut être reformuler en utilisant le gain informationnel (ou surprise) entre la distribution *a priori* ($p(H)$) et la distribution *a posteriori* ($P(H = u)$) sachant qu'une décision a été prise. Le gain informationnel associé à une décision u_j correspond à la divergence de Kullback-Leibler entre les distributions *a posteriori* et *a priori* :

$$KLD(p(H/u_j)||p(H)) = \sum_{i=\{0,1\}} \sum_{j=\{0,1\}} p(H_i/u_j) \log \frac{p(H_i/u_j)}{p(H_i)} \quad (2.39)$$

Sachant que : $p(H_0) = P_0$, $p(H_1) = P_1 = 1 - P_0$

En définissant le KLc comme la somme des KLD entre les distributions antérieure et postérieure, on peut l'écrire ce qui suit :

$$KLc = KLD(p(H/u_0)||p(H)) + KLD(p(H/u_1)||p(H)) \quad (2.40)$$

Ce qui donne :

$$\begin{aligned} KLc &= \frac{\alpha_0}{\alpha_0 + \beta_0} \log \frac{\alpha_0}{P_0(\alpha_0 + \beta_0)} \\ &+ \frac{\beta_0}{\alpha_0 + \beta_0} \log \frac{\beta_0}{(1 - P_0)(\alpha_0 + \beta_0)} \\ &+ \frac{\alpha_1}{\alpha_1 + \beta_1} \log \frac{\alpha_1}{P_0(\alpha_1 + \beta_1)} \\ &+ \frac{\beta_1}{\alpha_1 + \beta_1} \log \frac{\beta_1}{(1 - P_0)(\alpha_1 + \beta_1)} \end{aligned} \quad (2.41)$$

Où

$$\begin{aligned} \alpha_0 &= P_0(1 - P_F) \\ \alpha_1 &= P_0P_F \\ \beta_0 &= (1 - P_0)(1 - P_D) \\ \beta_1 &= (1 - P_0)P_D \\ P_0 &= p(H_0) \end{aligned} \quad (2.42)$$

L'optimisation du seuil peut se faire en minimisant la probabilité de détection manquée P_{mD} et en maximisant la probabilité de détection P_D , ce qui équivaut à maximiser KLc . Cette maximisation est atteinte en rendant la dérivée de KLc égale à zéro : $\frac{\delta KLc}{\delta th}|_{th=\lambda} = 0$, où th représente le seuil, et s'écrit comme suit :

$$\begin{aligned} \frac{\partial KLc}{\partial v} &= \\ \sum_{i \in \{0,1\}} &\left[\frac{\partial \alpha_i}{\partial v} \left[\frac{\beta_i}{(\alpha_i + \beta_i)^2} \log \left(\frac{1 - P_0}{P_0} \frac{\alpha_i}{\beta_i} \right) \right] + \frac{\partial \beta_i}{\partial v} \left[\frac{\alpha_i}{(\alpha_i + \beta_i)^2} \log \left(\frac{P_0}{1 - P_0} \frac{\beta_i}{\alpha_i} \right) \right] \right] \end{aligned} \quad (2.43)$$

La dérivée du critère KLc est détaillée ([5]). La probabilité d'absence de défaut(s) P_0 est calculée comme suit :

$$\hat{P}_0 = 1 - \frac{\sum_{i=1}^n h^i}{n} \quad (2.44)$$

Où $h^i = 0$ si on a choisit H_0 or $h^i = 1$ si on a choisit H_1 . Par conséquent, $\sum_{i=1}^n h^i$ représente une fenêtre de temps pour n hypothèses passées.

Critère de Bahattacharya Comme la divergence Kullback-Leibler, la divergence de Bhattacharyya possède son propre critère.

Le gain informationnel associé à une décision u_j correspond à la divergence de Bhattacharyya (BD) entre les distributions *a posteriori* et *a priori* est :

$$BD(p(H/u_j)||p(H)) = -\log \sum_{i \in (0,1)} p(H_i/u_j)^{\frac{1}{2}} q(H_i)^{\frac{1}{2}} \quad (2.45)$$

Ainsi, la somme des BD associées aux décisions u_0 et u_1 , est donnée par l'équation suivante :

$$Bc = BD(p(H/u_0)||p(H)) + BD(p(H/u_1)||p(H)) \quad (2.46)$$

En minimisant la somme des BD, le seuil est optimisé, le Bc peut être écrit comme suit :

$$Bc = - \left[\log(\alpha_0 + \beta_0) + \log(\alpha_1 + \beta_1) - \frac{1}{2} \log(\gamma_0) - \frac{1}{2} \log(\gamma_1) \right] \quad (2.47)$$

Avec :

$$\begin{aligned} \gamma_0 &= \frac{\alpha_0^2}{P_0} + \frac{\beta_0^2}{1 - P_0} \\ \gamma_1 &= \frac{\alpha_1^2}{P_0} + \frac{\beta_1^2}{1 - P_0} \\ \alpha_0 &= P_0 \sqrt{1 - P_F} \\ \alpha_1 &= P_0 \sqrt{P_F} \\ \beta_0 &= (1 - P_0) \sqrt{1 - P_D} \\ \beta_1 &= (1 - P_0) \sqrt{P_D} \end{aligned} \quad (2.48)$$

2.7.5 Les méthodes d'isolation de défauts

Après la génération des résidus et la détection des défauts, l'étape finale d'un schéma de diagnostic est l'isolation des défauts. En outre, dès l'instant où un défaut est détecté, une procédure d'isolation est promordial afin de déterminer l'origine de celui-ci. Généralement, cette étape s'appuie sur la génération de résidus de manière à ce qu'un ensemble de ces résidus soit sensible à certains défauts et insensible aux autres défauts. Dans la littérature, on peut distinguer : les résidus structurés et les résidus directionnels.

Dans le cadre de cette thèse, nous nous intéressons à une technique d'isolation aux résidus structurés nommée les observateurs à entrées inconnues (UIO).

Ce concept à a été largement étudié et appliqué sur des systèmes dynamiques qui puissent être modélisé comme ayant des entrées inconnues (par exemple, représentant des perturbations et des défauts). Le problème de la construction d'un observateur pour de tels systèmes a fait l'objet d'une attention considérable au cours des dernières décennies, et diverses méthodes de réalisation d'observateurs d'ordre complet ou réduit ont été présentées dans la littérature. Il a été démontré que les observateurs à entrées inconnues (UIO) s'avérera très

utile pour le diagnostic des systèmes surtout pour l'isolation des défauts de capteurs. L'UIO est défini dans ([28]) comme : "Un observateur est défini comme un observateur à entrée inconnue pour le système, si son vecteur d'erreur d'estimation d'état s'approche de zéro de manière asymptotique, indépendamment de la présence de l'entrée inconnue (perturbation) dans le système". Le concept général de la conception de la UIO consiste à découpler les perturbations de l'erreur d'estimation d'état.

En d'autres termes, l'idée est d'extraire un sous-système observable du système original, et dans ce sous-système, les défauts recherchés sont révélés, tandis que le reste du ou des défauts ne le sont pas. Ensuite, un gain d'observateur est obtenu par la famille des filtres de Kalman. Le choix du filtre informationnel se révèle donc très judicieux et plus adapté à ce type d'architectures. Là où dans la forme informationnelle, il suffira de retirer la contribution de chaque observation pour isoler la faute. Dans la littérature, il existe deux types d'approches différentes de la conception d'UIO : la première suppose une certaine information a priori sur les entrées non mesurables, tandis que la seconde suggère de reconstruire l'état du système linéaire par le biais d'un observateur capable de gérer la présence d'entrées inconnues.

Il est à noter que les méthodes UIO sont conçues pour un système linéarisé autour d'un

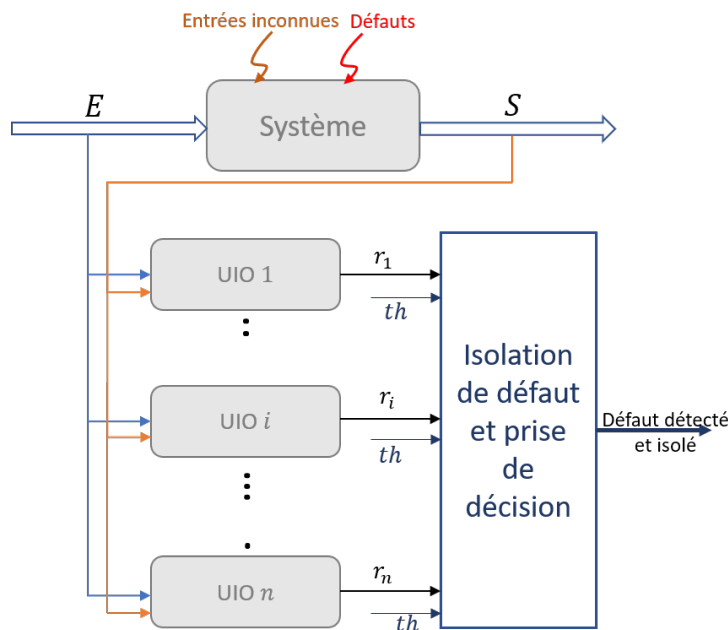


FIGURE 2.21 – Architecture UIO pour l'isolation de défauts

point de fonctionnement. Par conséquent, pour obtenir de bons résultats, la linéarisation ne doit pas entraîner une grande différence entre le modèle linéaire conçu et le comportement non linéaire. Ainsi, afin de concevoir une méthode UIO non linéaire, trois points principaux doivent être pris en considération :

1. Techniques basées sur la transformation d'état non linéaire,

2. Techniques basées sur la linéarisation,
3. observateurs pour des classes particulières de systèmes non linéaires.

La figure 2.21 présente un bref exemple de l'architecture UIO. Dans ce cas, un sous-ensembles d'observateurs sont utilisés pour chaque combinaison possible de défauts. Ainsi, un résidu est calculé pour chaque sous-ensemble et comparé au seuil pour prendre la bonne décision concernant ces défauts. Dans la littérature, ces techniques ont été évoquées dans plusieurs travaux concernant la tolérance aux fautes pour la fusion multi-capteurs. Dans [48], les auteurs proposent une méthode de détection et d'exclusion des défauts Fusion tolérante aux défauts satellitaires basée sur un banc de filtres de Kalman. Dans [47], ils proposent une architecture hybride basée sur un filtre de Kalman et des techniques de logique floue, où un ensemble de données de N capteurs sont introduites dans N filtres de Kalman. Un observateur logique flou est utilisé afin de superviser chaque filtre et de détecter les défauts des capteurs en évaluant la valeur du résidu.

2.8 Conclusion

Dans ce chapitre, nous avons présenté un état de l'art sur les capteurs utilisés avec leurs avantages et leurs inconvénients pour la localisation. Ensuite, nous avons expliqué l'idée et les avantages de combiner leurs observations et les différentes architectures possibles ont été présentées. Pour réaliser une telle combinaison ou fusion de capteurs, certains filtres stochastiques connues ont été discutés. Ensuite, on a présenté un état de l'art sur la fusion de données et sur le diagnostic d'une façon générale et les approches de fusion tolérante aux défauts capteurs. Ces approches nécessitent, dans la plupart des cas, une connaissance a priori des modèles des défauts, des informations sur les capteurs dans leur fonctionnement normal, de l'expertise, ou de la disponibilité suffisante des données. Dans ce contexte, on a présenté un bref état de l'art sur l'apport de l'apprentissage profond dans le domaine de la fusion multi-capteurs, ainsi que le diagnostic.

Dans le chapitre suivant, on présente l'approche proposée. Un formalisme adaptatif de fusion basée sur le filtre informationnel non linéaire ainsi que le résidu paramétré développé pour la détection des défauts selon contexte de navigation. Des méthodes d'optimisation pour la prise de décision selon le besoin opérationnel (sûreté/disponibilité) seront également présentées et développées.

Chapitre 3

Apprentissage profond pour la paramétrisation des résidus informationnels et seuillage d'une méthode de diagnostic adaptative : une solution au paradoxe des KPIs

Dans les applications quotidiennes, un système de localisation doit fonctionner dans un large panel de contextes, pour répondre à des exigences opérationnelles tel que l'intégrité et la précision. Dans ce chapitre, on propose un formalisme de fusion multi-capteurs tolérant aux fautes dont la couche de diagnostic est adaptative au contexte par apprentissage sur deux parties. Dans une première partie de ce chapitre, on présente la paramétrisation d'un résidu basée sur hybridation d'une approche informationnelle et d'une technique d'apprentissage en vue de détecter les mesures GNSS erronées. En deuxième partie, pour prendre la décision concernant ces mesures, une méthode de seuillage basée sur une fonction d'optimisation renforcée par une approche d'apprentissage profond est présentée.

3.1 Introduction

Dans la conception des applications automobiles, le système de localisation doit être à la fois précis et intègre, ce qui constituent deux exigences distinctes de la localisation. L'intégrité est souvent liée aux enjeux de sûreté, dont l'importance ne cessent de croître, comme en témoignent les nombreuses études récentes. Cependant, il existe un défi important

pour l'estimation de la position d'un véhicule, le changement de contexte de navigation. Il est difficile de maintenir une performance acceptable des capteurs, principalement les systèmes GNSS, dont la qualité de signal dépend de plusieurs facteurs en rapport avec l'environnement d'évolution du véhicule. Dans le chapitre 2, nous avons présenté les défauts auxquels peut être confrontés une méthode de localisation d'un véhicule autonome dans un environnement complexe.

Afin d'assurer l'intégrité et d'améliorer la précision du système de localisation, deux moyens complémentaires peuvent être employés : les algorithmes de détection et d'isolation de défauts et la fusion des données des capteurs. Par conséquent, ce chapitre met l'accent sur l'importance de la combinaison de ces deux approches pour améliorer le positionnement du véhicule. Dans ce travail, nous proposons une nouvelle formalisation du problème de la fusion de données et l'évaluation des performances des capteurs "**le concept d'adaptativité par apprentissage**". Le concept fondamental d'un système de localisation adaptatif au contexte a été proposé pour la première fois dans [129], ainsi que des résultats expérimentaux sur la détection et l'isolation des défauts selon le contexte de navigation.

Dans le prolongement des travaux précédents, cette étude vise à intégrer les méthodes d'apprentissage dans une couche de diagnostic pour détecter et isoler les défauts GNSS selon le contexte de navigation.

Ce chapitre est organisé comme suit. Il commence par une vue globale sur l'approche pro-

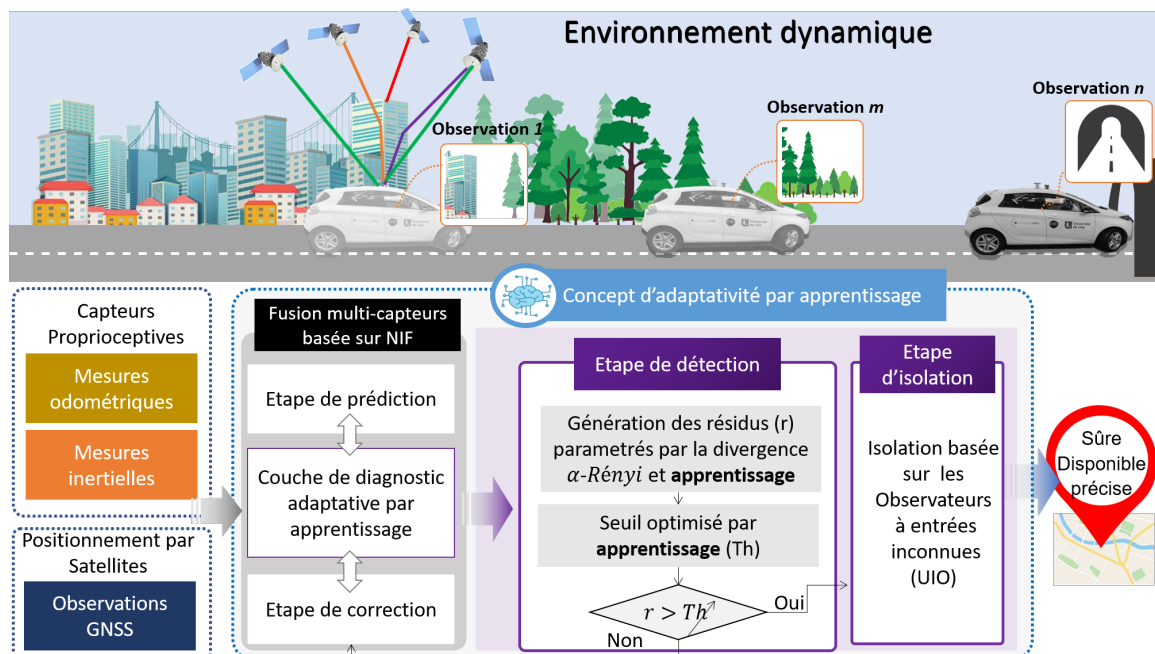


FIGURE 3.1 – Une architecture globale du concept d'adaptativité par apprentissage

posée, illustrée dans la figure 3.1. En premier lieu, la méthode de fusion multi-capteurs est mise en œuvre à travers l'utilisation des technologies GNSS, INS et odomètre. Pour assurer

un niveau de précision du système, cette méthode met l'accent sur l'ensemble des redondances disponibles entre les capteurs, basée sur une méthode de filtrage. Dans un second lieu, l'originalité de ce travail est soulignée. Pour garantir un niveau d'intégrité acceptable, nous proposons dans cette étude une méthode de détection et d'isolation de défauts GNSS basée sur une hybridation d'une approche théorique et une approche *data-driven* : une approche théorique qui se présente par une divergence informationnelle pour la génération de résidus et une approche orientée données consiste en l'intégration des techniques d'apprentissage automatique et profond sur deux niveaux de la couche de diagnostic :

- Paramétrisation des résidus selon le contexte de navigation par la sélection du paramètre α de la divergence α -Rényi.
- L'estimation d'un paramètre prédominant dans la sélection d'un seuil optimal, et par la suite prendre la décision la plus appropriée, en fonction des exigences opérationnelles du contexte de navigation.

3.2 Formalisme informationnel : Fusion tolérante aux fautes adaptative au contexte pour un véhicule autonome

La figure 3.2 résume l'approche générale pour une localisation adaptée au contexte environnementale. Le détail de chaque partie se trouve dans les sections suivantes. L'approche se constitue de deux sous-parties :

La première partie est **la fusion** des données multi-capteurs en utilisant les observations GNSS (pseudo-distances) et les données inertielles (accélérations et vitesses angulaires). Ensuite, un filtre informationnel non linéaire global (NIF) est utilisé afin de fournir les estimations des poses.

La deuxième partie consiste à détecter et isoler des défauts GNSS par **une méthode de diagnostic** basée sur un résidu paramétré et une méthode de seuillage **par apprentissage**.

Le processus de fusion est composé de deux étapes : l'étape de prédiction et de correction. Dans l'étape de prédiction, les mesures inertielles sont utilisées afin de déterminer le modèle d'évolution du système. Pour l'étape de mise à jour appelée également étape de correction les observations GNSS et les données odométriques sont employées.

Cependant, pour évaluer les mesures des capteurs et fournir un niveau d'intégrité acceptable, une couche de FDI adaptative au contexte est intégrée, basée sur deux étapes principales : la détection et l'isolation de défauts. Le processus de détection peut être divisé en trois parties :

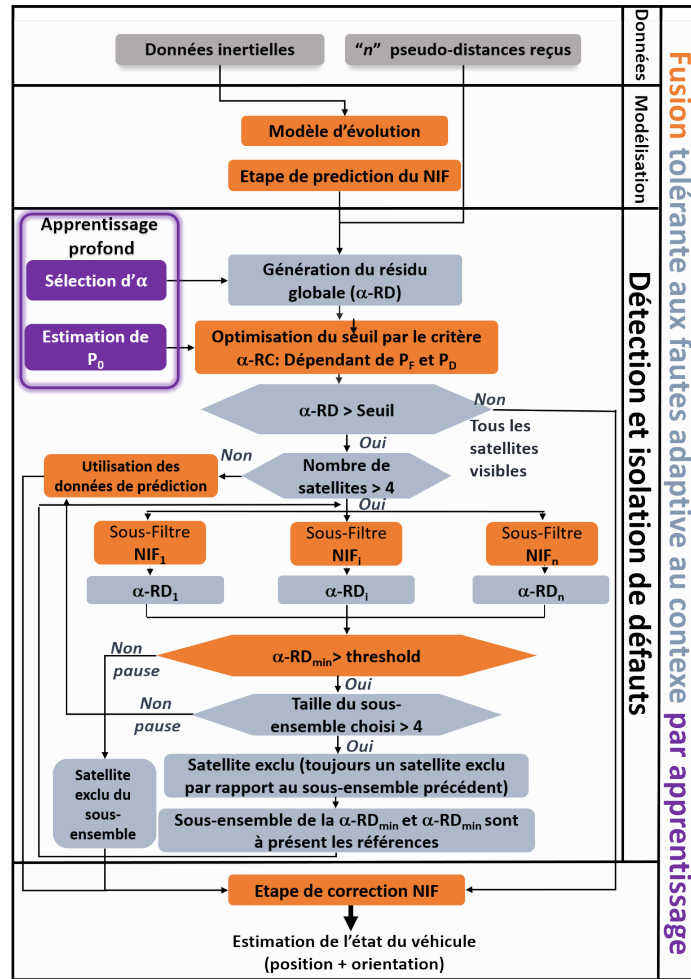


FIGURE 3.2 – L’architecture de la fusion tolérante aux défauts adaptative au contexte par apprentissage

1. La première étape est la génération des résidus paramétrés. D’abord, un résidu global est conçue à partir d’une mesure informationnelle appelée *Divergence α -Rényi*, connue comme la généralisation des différentes divergences et indexée par un paramètre α . Cette divergence mesure la dissimilarité entre la matrice de variance-covariance de l’état corrigé et la matrice de variance-covariance de l’état prédit. Le fait de procéder au test de dissimilarité sur les matrices de covariance (assimilables à des ellipsoïdes étant donné que le bruit est considéré de type gaussien), et non seulement sur la moyenne, permet d’exploiter toute l’information, soit la distance entre les moyennes ainsi que la différence de dispersion des nuages de points et leur orientation. Dans cette étude, le choix du paramètre α est déterminant pour la paramétrisation du résidu selon le contexte de navigation. La sélection de la valeur α est menée par une approche d’apprentissage automatique/profond.
2. La deuxième étape comporte une approche de seuillage basée sur une fonction d’op-

timisation définit comme le *critère d' α -Rényi*, avec th la valeur de seuil que le résidu généré ne doit pas dépasser. Cette fonction dépend de la probabilité d'absence de défauts P_0 . Cette valeur est estimée par un méthode d'apprentissage profond (réseau de neurones profond). Si le résidu global est inférieur au seuil spécifié, alors l'utilisation de toutes les observations dans l'étape de correction du NIF est possible pour estimer la position. Dans le cas inverse, l'étape d'isolement est activée pour exclure les mesures erronées.

La méthode d'isolation est un algorithme hiérarchique basé sur l'UIO, où à chaque niveau, des ensembles de sous-filtres NIF_n sont créés en utilisant le nombre d'observations disponibles au niveau $(n - 1)$. À chaque niveau, les résidus locaux α -RD sont calculés pour chaque sous-filtre et une mesure satellitaire erronée est retirée du niveau suivant. Ce processus se poursuit jusqu'à ce que toutes les mesures erronées soient retirées et que le sous-ensemble final d'observations ait un α -RD inférieur au th .

Enfin, cet sous-ensemble final est utilisé dans l'étape de correction du NIF et la position est estimée. Il est à noter que, durant tout ce processus, le nombre de satellites est pris en considération. En effet, il ne doit pas être inférieur à quatre satellites à l'instant k afin de fournir une position.

3.3 Fusion multi-capteurs : GNSS/INS/odomètre

Dans l'optique d'améliorer la précision et la disponibilité du système de localisation, cette section présente un couplage serré des données GNSS et des données inertielles basé sur un NIF. Le vecteur d'état est composé de 17 états : les mesures à partir du système inertielle INS, la position, la vitesse et l'attitude, exprimé dans le repère des coordonnées ENU (East, North, Up) pour définir un repère de travail proche de la zone de navigation du véhicule. Ce système de coordonnées est décrit en détails dans l'annexe B, les mesures à partir du capteur inertielle IMU, les biais des accéléromètres et des gyroscopes, dans le repère du véhicule et l'erreur de distance causée par les erreurs d'horloge (le biais d'horloge et la dérive d'horloge) du récepteur GNSS. Le vecteur d'état peut être écrit comme suit :

$$X_k = [p_x \ p_y \ p_z \ V_x V_y \ V_z \ a_x \ a_y \ a_z \ b_{xacc} \ b_{yacc} \ b_{zacc} \ b_{xgyro} \ b_{ygyro} \ b_{zgyro} \ c\delta t \ \dot{c}\delta t]^T$$

Où $p = [p_x, p_y, p_z]^T$ est la position estimée à l'instant k , $V = [V_x, V_y, V_z]^T$ est la vitesse, $a = [a_x, a_y, a_z]^T$ est l'attitude (roulis, tangage, lacet), b_{acc} est le biais d'accélération, b_{gyro} est le biais du gyroscope, c est la vitesse de la lumière, et δt et $\dot{\delta t}$ désignent respectivement le biais de l'horloge du récepteur GNSS et la dérive de l'horloge correspondante.

3.3.1 Estimation de la position du véhicule par NIF

Considérons le système non linéaire suivant :

$$X_{k+1} = f(X_k, u_k) + w_k \quad (3.1)$$

où, X_k est le vecteur d'état, $f(\cdot)$ est la fonction non linéaire, u_k est le vecteur d'entrée, et $w_k \sim \mathcal{N}(0, Q_k)$ est le bruit du modèle considéré comme un bruit blanc gaussien de moyenne nulle et de matrice de covariance Q_k .

Le modèle d'observation non linéaire a la forme suivante :

$$Z_k = h(X_k, \epsilon_k) \quad (3.2)$$

Où Z_k est le vecteur d'observations et ϵ_k est le vecteur de bruit d'observation considéré comme un bruit blanc gaussien de moyenne nulle et de matrice de covariance $R_k = E[\epsilon_k \epsilon_k^T]$.

Dans l'étape de prédiction, le modèle dynamique discret de l'INS est utilisé. La position, la vitesse et l'attitude sont dérivées à partir des mesures brutes de l'IMU à travers les équations de mécanisation simplifiées présentées comme suit :

$$\begin{aligned} p_{k+1} &= p_{n,k} + V_k \times T_s \\ V_{k+1} &= V_k + [R_{b2n,k} \times f_{b,k} + g_n] \times T_s \\ a_{k+1} &= a_k + E_{b2n,k} \times \omega_{b,k} \times T_s \\ b_{acc,k+1} &= b_{acc,k} + \nu_k \\ b_{gyro,k+1} &= b_{gyro,k} + \nu_k \end{aligned} \quad (3.3)$$

Où T_s est le temps d'échantillonnage, f_b est le vecteur de mesure de la force spécifique, g_n représente la gravité indiquée dans le repère de navigation (constante). ω_b représente le vecteur de vitesse angulaire, R_{b2n} est la matrice de rotation du repère du véhicule au repère de navigation ENU, et E_{b2n} est la matrice de transformation de la vitesse de rotation du repère du véhicule au repère de navigation, comme indiqué dans les équations suivantes :

$$R_{b2n} = \begin{pmatrix} c(\varphi)c(\theta) & c(\varphi)s(\theta)s(\phi) - s(\varphi)c(\phi) & c(\varphi)s(\theta)c(\phi) + s(\varphi)s(\phi) \\ s(\varphi)c(\theta) & s(\varphi)s(\theta)s(\phi) + c(\varphi)c(\phi) & s(\varphi)s(\theta)c(\phi) - c(\varphi)s(\phi) \\ -s(\theta) & c(\theta)s(\phi) & c(\theta)c(\phi) \end{pmatrix}, \quad (3.4)$$

$$E_{b2n} = \begin{pmatrix} 1 & s(\phi)t(\theta) & s(\phi)t(\theta) \\ 0 & c(\phi) & -s(\phi) \\ 0 & s(\phi)/c(\theta) & c(\phi)/c(\theta) \end{pmatrix} \quad (3.5)$$

Où $c(x)$, $s(x)$ et $t(x)$ représentent les opérations mathématiques de $\cos(x)$, $\sin(x)$ et $\tan(x)$, respectivement.

Pour prédire la position du véhicule, la matrice d'information et le vecteur d'information sont définies comme suit :

$$Y_{k+1|k} = [F_k P_k F_k^T + B_k Q_k^u B_k^T + Q_k]^{-1} \quad (3.6)$$

$$y_{k+1|k} = Y_{k+1|k} X_{k+1|k} \quad (3.7)$$

Ces équations s'écrivent dans l'étape de correction comme suit :

$$Y_{k|k} = Y_{k+1|k} + \sum_{i=1}^N gI_i(k) \quad (3.8)$$

$$y_{k|k} = y_{k+1|k} + \sum_{i=1}^N pI_i(k) \quad (3.9)$$

Le choix du filtre informationnel prend tout son sens dans l'architecture proposée dans la mesure où les équations (eq.3.8 et eq.3.9) qui permettent la mise à jour du vecteur d'état ne représentent qu'une somme des contributions informationnelles de chaque observation (contrairement à la forme classique du filtre de Kalman). Ainsi, il suffira de retirer la contribution de chaque observation afin d'isoler un défaut. Ainsi, les contributions informationnelles $gI_i(k)$ et $pI_i(k)$ sont calculées comme suit :

$$gI_i(k) = H_{i,k}^T R_i^{-1}(k) H_{i,k} \quad (3.10)$$

$$pI_i(k) = H_{i,k}^T R_i^{-1}(k) [(Z_{i,k} - \hat{Z}_{i,k}) + H_{i,k} X_{k+1|k}] \quad (3.11)$$

Où N est le nombre d'observations à l'instant k .

Sachant que :

Q_k^u est la matrice variance-covariance du vecteur d'entrée,

F_k est la matrice Jacobienne de f : $F_k = \frac{\partial f}{\partial X} |_{X=X_{k+1|k}}$,

B_k est la matrice jacobienne calculée comme suit : $B_k = \frac{\partial f}{\partial u} |_{u=u_k}$.

Selon [143], [66] et en se basant sur l'équation (3.3), la matrice F_k est exprimée comme

suit :

$$F_k = \left[\begin{array}{ccccc|cc} I_{3 \times 3} & I_{3 \times 3} T_s & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 2} \\ O_{3 \times 3} & I_{3 \times 3} & T_s [f_n \times] & T_s R_{b2n} & O_{3 \times 3} & O_{3 \times 2} \\ O_{3 \times 3} & O_{3 \times 3} & I_{3 \times 3} & O_{3 \times 3} & -T_s R_{b2n} & O_{3 \times 2} \\ O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & I_{3 \times 3} & O_{3 \times 3} & O_{3 \times 2} \\ O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & I_{3 \times 3} & O_{3 \times 2} \\ \hline O_{2 \times 3} & O_{2 \times 3} & O_{2 \times 3} & O_{2 \times 3} & O_{2 \times 3} & \begin{array}{cc} 1 & T_s \\ 0 & 1 \end{array} \end{array} \right] \quad (3.12)$$

Où $[f_n \times]$ est la matrice antisymétrique de $f_n = R_{b2n} f_b$.

La matrice d'observation H comprend la pseudo-distance du GNSS défini comme suit :

$$H = \left[\begin{array}{cccccc|cc} \nabla H_{xpr}^{x_1^s} & \nabla H_{ypr}^{y_1^s} & \nabla H_{zpr}^{z_1^s} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \nabla H_{xpr}^{x_i^s} & \nabla H_{ypr}^{y_i^s} & \nabla H_{zpr}^{z_i^s} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \nabla H_{xpr}^{x_m^s} & \nabla H_{ypr}^{y_m^s} & \nabla H_{zpr}^{z_m^s} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & O_{3 \times 3} & 1 & 0 \end{array} \right] \quad (3.13)$$

Où :

$$\begin{aligned} \nabla H_{xpr}^{x_i^s} &= \frac{\partial \rho^{x_i^s}}{\partial x} = \frac{x_i^s - \hat{x}_{pr}}{\rho^{si}} \\ \nabla H_{ypr}^{y_i^s} &= \frac{\partial \rho^{y_i^s}}{\partial x} = \frac{y_i^s - \hat{y}_{pr}}{\rho^{si}} \\ \nabla H_{zpr}^{z_i^s} &= \frac{\partial \rho^{z_i^s}}{\partial x} = \frac{z_i^s - \hat{z}_{pr}}{\rho^{si}} \end{aligned}$$

Avec :

ρ sont les pseudo-distances du GNSS. En plus de la fusion des technologies GNSS/INS, les mesures de l'odomètre sont utilisées compte tenu de leurs performances pour améliorer la position et atténuer l'erreur de l'INS. L'erreur de vitesse de INS est réduite en utilisant ce capteur supplémentaire. En supposant que la vitesse du véhicule à la sortie de l'odomètre est v_O , qui pointe directement devant le véhicule, c'est-à-dire parallèlement à l'axe X du système de coordonnées du véhicule, la vitesse tridimensionnelle dans le système de coordonnées du véhicule est exprimée sous forme vectorielle, de sorte que l'expression de la vitesse du véhicule dans le système de coordonnées de navigation est la suivante :

$$V_O^n = R_b^n [V_O, 0, 0]^T \quad (3.14)$$

3.4 Une couche de diagnostic adaptive au contexte de navigation par apprentissage

Une fois l'architecture de fusion multi-capteurs et le filtre d'intégration présentés, une couche de diagnostic adaptée au contexte de navigation et permettant d'atteindre les objectifs de sûreté de la brique de localisation est proposée. Dans cette étude, nous nous restreignons uniquement à la détection des défauts des observations GNSS générées par l'environnement local.

Comme présenté dans le chapitre 2, les systèmes GNSS sont devenus la principale solution de localisation pour la navigation extérieure des véhicules. Cependant, ces systèmes ont été conçus et dimensionnés pour des applications aériennes. En effet, l'utilisation des mesures GNSS pour la navigation terrestre n'est pas évidente, en sachant que l'environnement local perturbe la réception des signaux et peut entraîner une mauvaise estimation de la position, ce qui peut conduire à une situation aux conséquences graves pour les applications sécuritaires. Pour assurer la sûreté du système, la mise en œuvre d'une approche de FDI pour la détection de mesures aberrantes est nécessaire.

Ces méthodes sont généralement basées sur la génération de résidus, telle que la méthode de RAIM [197]. Cette approche utilise la redondance des mesures de pseudo-distance afin de vérifier la cohérence de la solution de navigation, en particulier pour les applications aéronautiques. Dans le contexte du RAIM, un résidu est construit à partir de la différence entre les mesures et les estimations obtenues par la solution des moindres carrés. Cette méthode offre de bonnes performances en ciel ouvert mais pas dans des conditions environnementales complexes (interférences multi-trajets, NLOS dans les canyons urbains, forêts...), dans ce cas une couche de détection et d'isolation multi-défauts appropriée devient primordiale à intégrer [25], [72].

3.4.1 Un résidu paramétrique basé sur la divergence de Rényi

Pour atteindre un niveau de sûreté requis, une couche de diagnostic doit être intégrée dans le processus de fusion plus précisément entre l'étape de prédiction et de correction du NIF. Dans ce travail, une méthode de FDI basée sur une mesure informationnelle est exploitée, pour générer un résidu. Chaque méthode de diagnostic comporte deux étapes : une étape de détection et une étape d'isolation des défauts.

Selon l'application, différentes mesures d'information sont utilisées dans la littérature pour générer un résidu sensible aux défauts à détecter [210] [24]. La sélection de la mesure informationnelle appropriée a un impact important sur le type de défauts à détecter et sur la performance générale de la couche de diagnostic. Plusieurs approches peuvent être citées pour la génération de résidus basés sur des divergences d'information, telles que la distance de

Mahalanobis, la divergence de Kullback Leibler. Dans cette étude, le choix de la divergence de Rényi (α -RD) est effectué en raison de sa capacité à proposer un paramètre α généralisant des divergences bien connues citées précédemment [111], [79]. Ce paramètre varie de 0 à l'infini ce qui aboutit à une infinité de résidu. Cela permet entre autre de jouer sur la répartition des confiances accordées entre le modèle d'évolution et les observations.

Pour rappel, l' α -RD entre deux distributions de probabilité P et Q est défini comme [111] :

$$RD_\alpha(P||Q) = \frac{1}{\alpha - 1} \ln \int P^\alpha(x)Q^{1-\alpha}(x)d(x) \quad (3.15)$$

Concrètement, le résidu de détection est basé sur la comparaison des distributions de probabilités gaussiennes des deux étapes du filtre informationnel $g(k + 1|k)$ l'étape de prédiction et $g(k + 1|k + 1)$ l'étape de correction. La génération de résidus par l' α -RD apporte plus de flexibilité et d'adaptabilité à un environnement dynamique et au type d'erreurs. Par conséquent, pour calculer la divergence entre les deux fonctions de distribution de probabilité, $g(k + 1|k)$ et $g(k + 1|k + 1)$, représentant les deux matrices de covariance de l'étape de prédiction et de correction fournies par NIF sont exploitées. En se référant à [79], le résidu $\alpha - RD$ est donné par l'équation suivante :

$$RD_\alpha(g(k + 1|k + 1)||g(k + 1|k)) = \frac{\alpha}{2}(X_{k+1|k+1} - X_{k+1|k})^T \left(\sum_{\alpha} \right)^{-1} (X_{k+1|k+1} - X_{k+1|k}) - \frac{1}{2(\alpha - 1)} \log \frac{|\sum_{\alpha}|}{|\sum_{k+1|k+1}|^{1-\alpha} |\sum_{k+1|k}|^{\alpha}} \quad (3.16)$$

Où $\sum_{\alpha} = \alpha \sum_{k+1|k} + (1 - \alpha) \sum_{k+1|k+1}$ et $\sum_{k+1|k} = \frac{1}{Y_{k+1|k}}$ and $\sum_{k+1|k+1} = \frac{1}{Y_{k+1}}$ Selon [129], l'équation 3.16 peut être exprimée également sous la forme :

$$RD_\alpha(g(k + 1|k)||g(k + 1|k + 1)) = \frac{\alpha}{2}(X_{k+1|k} - X_{k+1|k+1})^T \left(\frac{Y_{k+1|k}Y_{k+1|k+1}}{\alpha Y_{k+1|k} + (1 - \alpha)Y_{k+1|k+1}} \right) (X_{k+1|k} - X_{k+1|k+1}) + \frac{1}{2(\alpha - 1)} \log \left| \frac{Y_{k+1|k}Y_{k+1|k+1}}{\alpha Y_{k+1|k} + (1 - \alpha)Y_{k+1|k+1}} \right| + \frac{1}{2(\alpha - 1)} \log \frac{|Y_{k+1|k}|^{\alpha-1}}{|Y_{k+1|k+1}|^{\alpha}} \quad (3.17)$$

Ce résidu se présente sous la forme de trois types de tests qui traitent les deux distributions de probabilités de différentes manières :

$$RD_\alpha(g(k + 1|k)||g(k + 1|k + 1)) = testA + testB + testC \quad (3.18)$$

1. *Test A* : $(X_{k+1|k} - X_{k+1|k+1})^T \left(\frac{Y_{k+1|k}Y_{k+1|k+1}}{\alpha Y_{k+1|k} + (1 - \alpha)Y_{k+1|k+1}} \right) (X_{k+1|k} - X_{k+1|k+1})$ représente la distance de Mahalanobis pondérée. Ce test consiste à mesurer la distance entre les moyennes des deux distributions, en tenant compte de la valeur α qui pondère la distance par son impact sur les matrices de covariance.

2. *Test B* : $\log \left| \frac{Y_{k+1|k} Y_{k+1|k+1}}{\alpha Y_{k+1|k} + (1-\alpha) Y_{k+1|k+1}} \right|$ peut être comparé à la divergence de Bregman pondéré [19], en tenant compte du poids de α pour chaque matrice de covariance.
3. *Test C* : $\log \frac{|Y_{k+1|k}|^{\alpha-1}}{|Y_{k+1|k+1}|^{\alpha}}$ représente l'information mutuelle pondéré [184], où dans ce test, les deux distributions de probabilités sont comparés en fonction de leur valeur de pondération liée à la valeur de α .

L'ensemble de ces tests permet la génération du résidu généralisé α -RD, tout en témoignant d'une flexibilité pondérée entre le modèle d'évolution et les observations disponibles liée à la valeur de α .

3.4.2 Adaptativité d'une couche de diagnostic à l'environnement

Pourquoi la nécessité d'un diagnostic adaptatif au contexte ?

La navigation en milieu extérieur, en particulier la localisation en extérieur est un champ de recherche qui ne cesse d'attirer l'intérêt des chercheurs et des industriels du transport, dans la mesure où les problèmes rencontrés n'ont jamais été autant d'actualité. L'exploitation des capteurs à faible coût, tels que les systèmes GNSS, l'IMU et l'odomètre, a contribué de manière significative à l'évolution des véhicules autonomes par le biais des algorithmes développés tel que l'intégration et le diagnostic des mesures capteurs. Ces algorithmes sont de plus en plus avancés mais doivent être certifiés pour des applications nécessitant l'accord des autorités de régulation avant d'être mis sur le marché. Pour la localisation, l'évolution des algorithmes tend à prendre en compte ce qu'on appelle l'adaptativité au contexte de navigation [53]. Dans la prochaine sous-section, nous détaillons l'impact du contexte de navigation sur la couche de diagnostic. Ainsi, les motivations pour le développement d'une méthode de FDI adaptée au contexte par apprentissage sont présentées. Enfin, l'approche complète est expliquée.

Le changement d'environnement

La difficulté principale, lorsqu'il s'agit d'assurer la sûreté d'une brique de localisation dans une application sécuritaire intégrant les données GNSS, est l'impossibilité de considérer cette technologie comme un capteur à point de fonctionnement unique. Il est invisable de considérer une valeur unique de taux de défaillance du système. Ce taux est grandement variable, selon le nombre de satellites visibles, leur disposition géométrique, les conditions de réceptions locales (blocage satellitaire, interférences) et d'autres paramètres qui serait trop long à lister. C'est donc un capteur qui est très sensible aux contexte dans lequel il évolue.

Adopter une couche de diagnostic qui considérerait des statistiques constantes de présence de défaut ne serait pas rigoureux.

Le changement d'exigences opérationnelles

D'autres éléments conduisent à réfléchir au développement d'une couche de diagnostic adaptative. Parmi eux, un élément qui nécessite une vue macroscopique du système. En effet, lorsqu'on ne pense pas seulement au véhicule mais à l'environnement dans lequel il évolue, il devient évident que les besoins opérationnels attendus du système de positionnement sont également variables dans le temps. En effet, que le véhicule circule en rase campagne ou qu'il circule dans un canyon urbain, les exigences sur la précision attendue ou sur la continuité ne sont pas les mêmes. Ces exigences opérationnelles, à travers un processus complexe impactent les métriques liées au niveau de protection procuré avec l'estimation de la position (une « bulle » garantissant à un pourcentage élevé que la vraie position se situe à l'intérieur) ou encore les probabilités de fausses alarmes et de détection manquée des incohérences d'observations.

Vers un compromis entre la disponibilité et la sûreté

Les exigences liées à la sûreté et celles liées à la disponibilité sont typiquement le type d'exigence contradictoire qui conduit à une situation où un compromis doit être trouvé. De toute évidence, le terme compromis est inadéquat et ne doit pas être utilisé lorsque l'on traite de sûreté. Généralement, les exigences relatives à la sûreté sont exprimées en terme de taux de danger tolérable THR (*en anglais : Tolerable Hazardous Rate*) qui représentent une limite maximale d'itération de défaillances système. Pour atteindre l'objectif, une politique de diagnostic très conservatrice est nécessaire. Au moindre soupçon d'erreur, cette politique préférera rendre la fonction de localisation indisponible. Nous pouvons voir ici l'impact négatif que ce type de politique trop conservatrice peut avoir sur la disponibilité et la continuité du service. Avoir un diagnostic adaptatif permet d'envisager de relâcher les contraintes de sûreté selon le contexte tout en s'assurant que le THR demandé n'est pas dépassé pour améliorer la disponibilité. En d'autres termes, un diagnostic standard permet de poursuivre un seul objectif (soit minimiser la probabilité de fausse alarme ou la probabilité de détection manquée) là où un diagnostic adaptatif ajoute un degré de liberté permettant en fonction du changement d'environnement et / ou des KPI de parvenir à un compromis entre ces deux objectifs.

3.4.3 Quelques méthodes utilisées pour la localisation dans un environnement complexe

La compréhension et l'analyse du contexte environnemental d'un véhicule autonome joue un rôle essentiel dans la conception des applications de localisation adaptées au contexte. Dans la littérature, plusieurs techniques ont été proposées pour améliorer le positionnement GNSS dans un environnement complexe. Ces méthodes sont détaillées dans les paragraphes suivants.

Utilisation de multi-constellations pour augmenter le nombre d'observations GNSS

Pour le positionnement à l'aide d'une constellation, au moins quatre signaux de satellites sont nécessaires pour aboutir à une solution de positionnement. Dans les zones urbaines, cette condition n'est pas toujours respectée en raison du blocage des signaux par les bâtiments. Pour améliorer l'intégrité du système de localisation, le nombre de signaux GNSS disponibles peut être augmenté en faisant intervenir des constellations supplémentaires et exploiter cette redondance des satellites. En fonction de la stratégie de positionnement, Une fois que l'on a ajouté une constellation de satellites supplémentaire, il peut être nécessaire d'avoir un satellite de plus pour estimer le décalage temporel du système afin de proposer une solution de navigation. Dans certains cas, les signaux des satellites ajoutés sont susceptibles d'être une source d'erreur pour la solution de localisation.

Implémentation de modèles de bâtiments 3D pour détecter les défauts GNSS et compenser leurs effets pour le positionnement

Les modèles de bâtiments en 3D peuvent être utilisés pour prédire si les signaux sont bloqués ou directement visibles lorsque l'emplacement est connu. Comme le montre la figure 3.3, la technique de correspondance d'ombre (*en anglais : Shadow matching*) GNSS détermine la position en comparant la présence et la puissance du signal reçu avec les prédictions faites à l'aide d'un modèle 3D de la ville. Cela permet d'atteindre des précisions de positionnement de quelques mètres dans des zones urbaines denses où l'erreur de positionnement GNSS conventionnelle est de plusieurs dizaines de mètres [198].

Modèles de pondération des observations GNSS

Les configurations satellitaires sont souvent étudiées, plus les angles d'élévation ainsi que les rapports signal/bruit sont élevés, moins le signal est susceptible d'être contaminé par des perturbations tel qu'une réception NLOS ou des trajets multiples. Sur la base de cette hypothèse, l'effet de ces perturbations peut être simplement atténué en sélectionnant les




FIGURE 3.3 – Principe de la méthode de correspondance d'ombre 'Shadow matching' [68]

signaux dont les élévations sont élevées ou en rejetant/réduisant les mesures à faible rapport signal/bruit (C/N_0). Ainsi, l'impact de ces perturbations sur la solution de localisation peut être réduit, mais pas complètement éliminé. Dans ce contexte, plusieurs stratégies ont été proposées dans la littérature pour la pondération des observations GNSS, telles que le modèle d'élévation sinusoïdal [195] où les observations GNSS sont pondérées en fonction des élévations des satellites ou les modèles $\sigma\text{-}\Delta$ et $\sigma\text{-}\epsilon$ une pondération en fonction du C/N_0 [20, 206]. Ces modèles ont montré leur efficacité dans des zones urbaines.

Cependant, ces modèles ne sont peut-être pas la politique idéale car ils ne peuvent considérer qu'un seul paramètre et peuvent difficilement obtenir des résultats satisfaisants pour toutes les exigences opérationnelles mentionnées ci-dessus et dans un large éventail de contextes d'exploitation [67]. Dans des travaux récents, d'autres paramètres tels que le nombre de satellites disponibles, le Code-Minus-Carrier (CMC), la Dilution de Précision (DOP) permettent de mieux évaluer le contexte de navigation [147].

3.5 La stratégie proposée

Bien qu'il existe de nombreuses recherches sur l'adaptation du système de localisation au contexte de navigation. Ces méthodes restent performantes que dans certains environnements principalement urbains [67]. Ces dernières années, l'apprentissage automatique et, par extension, l'apprentissage profond ont connu un succès considérable dans le domaine des véhicules autonomes. Cependant, le débat du degré d'intégration de ces méthodes dans ces applications est sans fin. Certains, adeptes de la discipline de l'automatique pure les rejeteront. D'autres

adoptent une posture inverse qui consisterait à considérer ces techniques comme la réponse à tout problème. La posture adoptée dans nos recherches consiste à utiliser la modélisation mathématique, puis d'augmenter ces modèles mathématiques par l'utilisation des algorithmes d'apprentissage afin d'ajuster leurs paramètres. Cependant, ces algorithmes peuvent avoir des décisions difficilement interprétables et un comportement incontrôlable.

En effet, les tâches se compliquent quand il s'agit des applications qui exigent un niveau de sûreté élevé et une certification au près d'autorités régulatrices. Tout comportement, ou décision doit être explicable, anticipable, répétable, vérifiable et validable. La localisation est un exemple parfait qui démontre l'utilité des méthodes d'apprentissage. Les modèles d'erreurs d'observations GNSS sont variables selon le contexte considérant sa sensibilité à l'environnement. Comme présenté dans le chapitre 2, dans certains travaux le filtre d'intégration des capteurs est remplacé par un réseau de neurones. Dans d'autres travaux, ce filtre est « augmenté » par les méthodes d'apprentissage pour l'estimation en temps réel des bruits des modèles d'évolution et d'observation. Dans cette étude, les algorithmes d'apprentissage sont utilisés comme un outil, qui contribue à la flexibilité à la couche FDI pour s'adapter à un large panel de contextes de navigation et augmenter les performances du système de localisation.

Dans ce cadre, le paramètre α de la divergence de Rényi représente un degré de liberté supplémentaire pour la couche de diagnostic. Il permet de sélectionner, parmi un nombre infini de résidus, celui qui maximise la détectabilité des défauts, notamment des défauts soudains. La sélection du paramètre est basée sur deux méthodes différentes. Dans un premier temps, cette sélection est faite par une fonction '*Sigmoid*'. Par la suite, la sélection d' α basée sur une méthode d'apprentissage qui prend en compte plusieurs caractéristiques, parmi lesquelles les incertitudes des modèles d'évolution et d'observation.

3.5.1 La sélection du paramètre α

Une sélection basée sur une fonction logistique *Sigmoid*

Afin de franchir une première étape vers l'adaptation du contexte de navigation, diverses approches existent dans la littérature (voir section 3.4.3). Principalement, ces méthodes sont basées sur la modélisation des erreurs dans la matrice de covariance des observations GNSS. Pour rappel, les modèles $\sigma\text{-}\epsilon$ et $\sigma\text{-}\delta$ qui évaluent l'impact de la qualité du signal reçu sur les erreurs de mesure en fonction du C/N_0 [20],[206]. En parallèle, d'autres études [117], [59] se sont intéressées à l'impact de l'élévation des satellites sur les erreurs de mesures en considérant que les perturbations locales (NLOS, multitrajets) affectent fortement les satellites de faible élévation. Par conséquent, un modèle d'élévation de type sinus a été proposé dans [195]. Après la comparaison des deux modèles, des travaux du [127] ont conclu que les

mesures des satellites à haute élévation sont davantage limitées par un modèle basé sur C/N_0 , tandis que pour les satellites à faible élévation, le modèle basé sur l'élévation est performant. Par conséquent, une politique plus efficace peut utiliser les informations des deux critères.

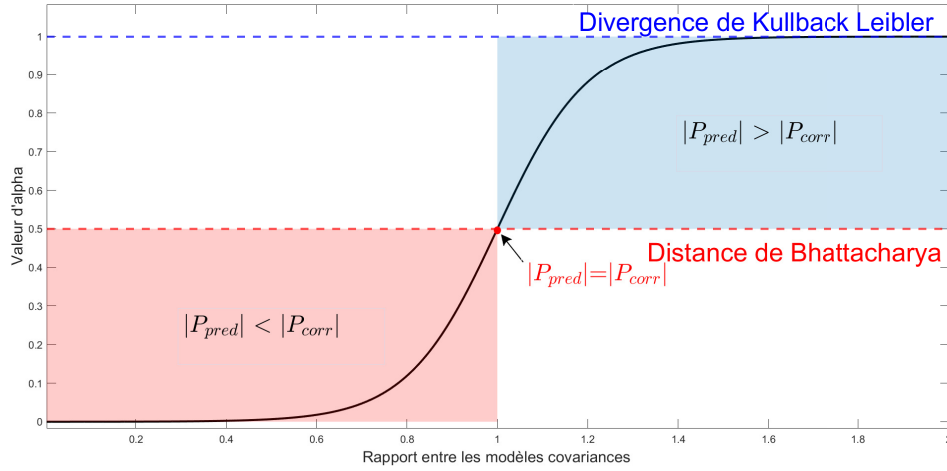


FIGURE 3.4 – Illustration de l'approche de paramétrisation de résidu α -RD par une fonction sigmoïde

En se référant à la pondération de [183], nous proposons de pondérer les observations GNSS, où l'estimation de la matrice de variance-covariance R_k prend en compte les élévations (el) et le C/N_0 des satellites disponibles à chaque instant par :

$$\sigma_{i,k}^2 = l \frac{10^{-\frac{C/N_0_i}{10}}}{\sin^2(el_i)} \quad (3.19)$$

Où l est un coefficient représentant un indicateur du signal direct LOS *a priori*, i est le i_{ieme} satellite visible, ainsi R_k est définie comme suit :

$$R_k = \begin{pmatrix} \sigma_{1,k} & & & & \\ & \ddots & & & \\ & & \sigma_{i,k} & & \\ & & & \ddots & \\ & & & & \sigma_{n,k} \end{pmatrix} \quad (3.20)$$

La figure 3.4 illustre l'approche proposée pour réévaluer constamment le paramètre α approprié, en considérant le rapport de force entre les deux incertitudes prises en compte dans le résidu. On propose une stratégie de pondération de la matrice des variance-covariance par α sous la forme d'une fonction sigmoïde généralisée d'un intervalle $]0, 1[$ [142]. L'équation de cette fonction prend en compte le rapport entre la matrice de de variance-covariance pondérée

de l'étape de correction et la matrice de variance-covariance de l'étape de prédiction.

$$\alpha = A + \frac{K - A}{(C + Qe^{-B \frac{|\sum_{k+1}^k|}{|\sum_{k+1}^{k+1}|}})^{\frac{1}{\nu}}}. \quad (3.21)$$

Où $A = 0$, $K, C = 1$, $\nu=1$, Q and B sont des paramètres calibrés en fonction de la pente requise de la fonction [142].

Une sélection basée sur un approche d'apprentissage

Dans le optique de satisfaire une politique multicritère et d'assurer l'adaptabilité complète au contexte de navigation, une nouvelle formulation du problème de sélection du paramètre α de la divergence de Rényi est proposée.

La figure 3.5 présente une approche de paramétrisation de résidu α -RD basée sur des algorithmes d'apprentissage supervisé et non supervisé (la différence entre les deux méthodes est détaillée dans l'annexe A). Cette approche est composée de différentes étapes. Chaque étape est décrite en détail ci-dessous.




FIGURE 3.5 – Illustration de l'approche de paramétrisation de résidu α -RD par une méthode d'apprentissage dans l'algorithme de détection de défauts

- *La collection des données GNSS* : La première étape pour tester et valider l'approche proposée est l'aquisition des données des capteurs. Dans cette étude, les mesures brutes GNSS sont collectées de deux sources différentes, détaillées dans le chapitre 4 section 4.5.1.
- *Le prétraitement des données et extraction des caractéristiques* : Après avoir collecter un nombre important des données, on passe au prétraitement ou la préparation des données ; normalisation, transformation. L'objectif principal de la préparation des données est de s'assurer que les informations collectées pour l'analyse sont exactes et cohérentes, afin que les résultats de l'application et d'analyse soient valides. Par la suite,

une sélection des paramètres pertinentes qui caractérise le mieux un signal GNSS est effectuée par expertise.

- *Le partitionnement des données* : après la collection et la sélection des données, une catégorisation du contexte environnemental basée sur un algorithme d'apprentissage automatique non supervisé appelé " *K-means*" est effectuée. L'objectif de cet algorithme est de répartir les données GNSS en groupes homogènes, c'est à dire des groupes dont les signaux GNSS reçus présentent des caractéristiques communes. En se basant sur ces caractéristiques, les contextes environnementaux sont classés comme suit ; ciel ouvert, environnements sous-urbains, urbains et couverts.
- *La Labellisation de la valeur du paramètre α* : une fois les contextes environnementaux sont définits, une étape primordiale pour la conception d'un réseau de neurones profond est la Labellisation (ou étiquetage) de sortie (α). Cette étape est réalisé par l'intermédiaire de la couche de FDI, où 10 valeurs du paramètre α de $[0, 1[$ sont appliquées à chaque groupe. Par la suite, une caractérisation de résidu est faite à chaque fois qui en résulte deux distributions de probabilités (avec et sans défaut). Ainsi, pour chaque groupe un algorithme appelé '*IoU*' (*Intersection over Union*) mesurant le chevauchement entre ces deux distributions, c'est à dire réduire au maximum la probabilité de fausse alarme P_{fa} et la probabilité de détection manquée P_{mD} pour chaque valeur d' α est appliqué à chaque groupe. Pour chaque groupe de données "context de navigation", la valeur du paramètre α qui minimise ce chevauchement, est la valeur choisie comme étiquette pour ce groupe.
- *L'entraînement du réseau de neurones et la sélection de la valeur du paramètre d' α* : La sélection de la valeur du paramètre α est considérée comme un problème de régression. Pour résoudre ce problème, on propose un algorithme d'apprentissage spécifique pour la régression supervisée. C'est un réseau de neurones profond nommé 'le perceptron multicouche (*en anglais multilayer perceptron MLP*), il est constitué d'unités de calcul élémentaires appelés neurones. Un neurone possède des entrées, qui sont des variables à valeur réelles, notées x_1, \dots, x_n , et une sortie, notée y (paramètre α). Or, l'apprentissage supervisé consiste à entraîner un réseau de neurones à partir de données labellisées, c'est-à-dire, à chaque observation GNSS doit être associée une valeur du paramètre α . D'abord, les données sont divisées en deux parties : données d'entraînement et données de test. A partir de milliers de données étiquetés : un modèle d'entraînement établit une relation fonctionnelle entre les caractéristiques d'une observation GNSS et la sortie le paramètre α . Une fois le modèle est entraîné, ce modèle peut ensuite généraliser cette régression au données de test, c'est à dire à de nouvelles données qu'il n'a jamais vues durant la phase d'apprentissage. C'est ce qu'on appelle la capacité de généralisation. Enfin, le modèle est évalué en terme d'erreur et la valeur α est estimée

pour chaque observation à chaque instant.

- *L'intégration du résultat du MLP dans la paramétrisation du résidu* : Une fois que le paramètre α est déterminé en utilisant le réseau de neurones, il est implémenté dans l'algorithme de FDI afin de générer un résidu paramétré.

3.6 Adaptation de la décision en fonction du contexte

Chaque méthode de détection de défauts comporte une étape de génération des résidus et une étape d'évaluation de résidus. En effet, Une fois que la valeur du paramètre α est sélectionnée et que les résidus sont générés. Une procédure de seuillage doit être intégrée afin d'extraire l'information relative aux défauts et de prendre une décision au sujet des mesures aberrantes. L'une des méthodes la plus commune dans la littérature est la fixation d'un seuil de détection des défauts, dès qu'un résidu dépasse la valeur du seuil, on peut affirmer qu'on a réalisé une détection.

Dans la littérature, ce seuil est défini de différentes manières, en se basant principalement sur des méthodes statistiques, notamment le rapport de vraisemblance généralisé décrit en [10]. Dans certaines études, cette valeur est fixée d'une manière heuristique en choisissant une probabilité constante de taux de fausse alarme comme le soulignent les travaux dans [5]. Ensuite, différentes techniques d'optimisation ont été proposées pour le calcul du seuil. Par exemple, dans [193] les auteurs ont proposé un seuil adaptatif basé sur des simulations de Monte-Carlo et une estimation du quantile de la statistique de test. Dans [163], la courbe ROC est présentée comme une solution pour détecter les défauts dans un système multi-capteurs. Cependant, ces techniques considèrent un environnement statique. Elles impliquent donc une forte limitation des performances de détection dans la mesure où la probabilité de faire face à un défaut de mesure dépend de l'environnement traversé qui est par nature dynamique.

3.6.1 Méthode de seuillage basée sur une fonction d'optimisation informationnelle le critère de Rényi R_{C_α}

Dans l'optique d'assurer la disponibilité du système, la fixation du seuil est basée généralement sur la minimisation de la probabilité de fausse alarme P_{fa} . Mais, cette politique peut être insuffisante pour garantir toutes les exigences opérationnelles telles que la sûreté qui, dans la plupart des cas, peut être liée à la P_{mD} . Pour assurer un compromis optimal entre les exigences opérationnelles, et donc entre ces deux probabilités, une fonction d'optimisation de la décision a été conçue.

Afin de concevoir cette fonction d'optimisation, il est possible de considérer le problème sous deux possibilités :

- une fonction de récompense, dont l'objectif est de maximiser les cas où la décision est en accord avec l'hypothèse $p(H_0/u_0)$ et $p(H_1/u_1)$, donc la probabilité d'absence de défaut P_0 et la probabilité de détection P_D (ces probabilités sont définies dans la section 2.7.4).
- une fonction de risque, dont le but est de minimiser les cas où la décision est contraire à l'hypothèse $p(H_1/u_0)$ et $p(H_0/u_1)$, donc la probabilité de fausse alarme P_{fa} et la probabilité de détection manquée P_{mD} .

Dans cette étude, nous optons pour une fonction de risque (une fonction d'optimisation informationnelle nommée *le critère de Rényi* Rc_α), considérant que le coût attribué à une mauvaise décision est plus élevé que celui attribué à une bonne décision. Et pour faciliter l'étape d'optimisation, on introduit une échelle logarithmique en utilisant la divergence utilisée pour concevoir le résidu.

D'après l'équation 3.15, le gain informationnel associé à la décision u_j , représente la divergence α -Rényi entre les distributions *a priori* et *a posteriori*. Ce gain peut être écrit comme suit :

$$RD_\alpha(p(H/u_j)||p(H)) = \frac{1}{\alpha - 1} \log \sum_{i,j \in \{0,1\}} (p(H_i/u_j))^\alpha (p(H_i))^{1-\alpha} \quad (3.22)$$

Par conséquent, le critère Rc_α représenté par la somme du gain informationnel, s'écrit comme suit :

$$Rc_\alpha = [RD_\alpha(p(H_i/u_j)||p(H_i)) + RD_\alpha(p(H_j/u_i)||p(H_j))] \quad (3.23)$$

avec $i \neq j$

Ce qui donne :

$$Rc_\alpha = \frac{1}{\alpha - 1} \left[\log \left(\frac{p(u_1/H_0)}{p(u_1)} \right)^\alpha p(H_0) + \log \left(\frac{p(u_0/H_1)}{p(u_0)} \right)^\alpha p(H_1) \right] \quad (3.24)$$

Ainsi, la dérivation de cette fonction développée dans les travaux [129] a prouvé que le maximum de cette fonction de risque correspond au seuil optimal Λ .

Ainsi, le critère α -Rényi s'écrit comme suit :

$$\Lambda \underset{H_0}{\overset{H_1}{\gtrless}} \frac{a(A_{01} + A_{10}) + b(B_{01} + B_{10}) + \frac{PM}{V}}{C_{01}(A_{01} - A_{10}) - C_{10}(A_{01} + A_{10}) + d(B_{01} + B_{10}) + \frac{PN}{V}} \quad (3.25)$$

Où :

$$\begin{aligned}
 l_{ij} &= P_0 \beta_j \gamma_i + (1 - P_0) \beta_j \beta_i \\
 n_{ij} &= P_0 \gamma_i \gamma_j + (1 - P_0) \beta_j \gamma_i \\
 A_{ij} &= l_{ij}^\alpha, \quad B_{ij} = n_{ij}^\alpha, \quad C_{ij} = n_{ij}^{\alpha-1} (1 - P_0) \gamma_0 \\
 a &= [-P_0(\gamma_0 - \gamma_1) + (1 - P_0)\beta_1] n_{ij}^{\alpha-1} + [-P_0(\gamma_0 - \gamma_1) - (1 - P_0)\beta_0] n_{ji}^{\alpha-1} \\
 b &= l_{ij}^{\alpha-1} P_0 \beta_1 - l_{ji}^{\alpha-1} P_0 \beta_0 \\
 d &= P_0 \gamma_0 - (1 - P_0)(\beta_0 + \beta_1) l_{ij}^{\alpha-1} - P_0 \gamma_1 + (1 - P_0)(\beta_0 - \beta_1) l_{ji}^{\alpha-1} \\
 P &= (n_{ij}^\alpha + n_{ji}^\alpha)(l_{ij}^\alpha + l_{ji}^\alpha) \\
 M &= 2P_0^2(\gamma_0 - \gamma_1) + 2P_0(1 - P_0)(\beta_0 - \beta_1) \\
 N &= 2(1 - P_0)(\gamma_1 - \gamma_0) + 2(1 - P_0)^2(\beta_1 - \beta_0) \\
 V &= P_0^2 \gamma_0 \gamma_1 + (1 - P_0)P_0 \gamma_0 \beta_1 + (1 - P_0)P_0 \beta_0 \gamma_1 + (1 - P_0)^2 \beta_0 \beta_1
 \end{aligned} \tag{3.26}$$

Et :

$$i = \bar{j} \in \{0, 1\}$$

Le critère informationnel pour l'optimisation du seuil global est présenté comme suit :

Algorithm 1: La fonction d'optimisation du seuil basée sur le critère informationnel α -Rc

L'estimation de P_0 par RNP ; $Rc_{\alpha max} = 0$;

for $\lambda = \lambda_{min}$ **to** λ_{max} **do**

Calculer P_D^λ and P_F^λ

calculer α -RD $_\lambda$

if α -RD $_\lambda > \alpha$ -Rc $_{max}$ **then**

α -Rc $_{max} = \alpha$ -RD $_\lambda$;

$P_D^{opt} = P_D^\lambda$;

$P_F^{opt} = P_F^\lambda$;

$\lambda_{opt} = \lambda$;

end

end

En fonction de l'application, cette méthode offre une plage de réglage permettant de choisir le seuil approprié à chaque cas. Pour calculer ce seuil, il faut prendre en compte une valeur d'un paramètre critique qui a un impact prépondérant sur la décision. Ce paramètre peut être considéré comme la jauge pour prendre la décision appropriée qui dépend essentiellement du contexte de navigation : la probabilité P_0 de l'hypothèse « absence de défaut ». Généralement, pour estimer cette valeur à chaque instant, une méthode appelée MLE (*Maximum Likelihood Estimation*) [5] est employée. Pour prendre une décision, cette méthode prend en

compte l'historique du comportement du système sous forme d'une fenêtre temporelle.

Cependant, cette méthode présente certaines limites :

- La taille de la fenêtre temporelle et la valeur initiale de P_0 sont fixées heuristiquement.
- La détection tardive des erreurs cumulées
- La détection erronée de certaines erreurs soudaines

Par conséquent, cette approche ne tient pas compte des changements soudains de l'environnement ou des exigences opérationnelles. En effet, cette méthode ne permet pas de traiter tous les types d'erreurs, en particulier les plus menaçantes comme les erreurs soudaines du GNSS. Il est donc indispensable de développer une approche de seuillage qui s'adapte au contexte et aux exigences opérationnelles. Dans la section suivante, une approche basée sur un réseau de neurones profond pour l'estimation de P_0 est proposée. Ensuite, l'intégration du P_0 estimée dans la partie de seuillage est également détaillée.

3.6.2 L'estimation de P_0 et son intégration dans l'algorithme FDI

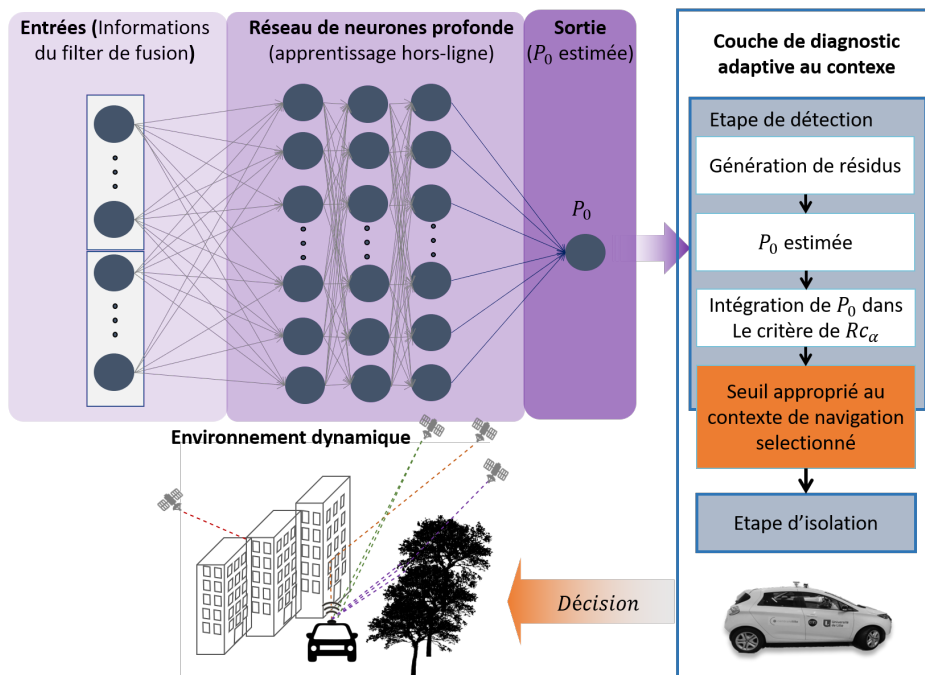


FIGURE 3.6 – Illustration d'intégration de la valeur estimée de P_0 par un réseau de neurones profond dans l'algorithme de détection de défauts

La figure 3.6 illustre l'intégration de l'estimation de P_0 dans le processus de seuillage. Cette estimation est basée sur méthode d'apprentissage supervisé, particulièrement un réseau de neurones profond (RNP) pour une tâche de régression. Tout d'abord, une procédure

d'apprentissage hors ligne est nécessaire pour sélectionner le modèle le plus approprié afin d'estimer la valeur de P_0 . Pour atteindre cet objectif, le processus de détection est exploité pour sélectionner les entrées (des informations sur les signaux GNSS et des informations venant du filtre de fusion) du réseau de neurones dans un premier lieu. Et par la suite, avoir un ensemble de données de sortie étiquetées pour établir un lien fonctionnel entre les données d'entrées et la valeur de P_0 désirée.

La procédure d'apprentissage est composée d'une étape d'entraînement et d'une étape de test, cette dernière étape peut être considérée comme la validation de la performance du modèle d'entraînement. Lorsque l'étape de test fournit un P_0 satisfaisant selon les données étiquetées (évaluées par une fonction de perte), le RNP est considéré comme suffisamment entraîné. Dans ce cas, la sortie du réseau de neurones (P_0 estimé) est intégrée dans le processus de détection en ligne. Par la suite, cette valeur est utilisée pour le calcul du critère Rc_α dans le but d'adapter la décision au contexte. Ensuite, la décision concernant la présence de défaut(s) est prise, et enfin suivie par une étape d'isolation des défauts. Cependant, lors de l'utilisation des méthodes d'apprentissage profond, la collecte et la sélection des données d'apprentissage sont d'une importance capitale pour concevoir les connaissances souhaitées sur l'environnement de l'utilisateur et établir un lien entre les entrées choisies et les sorties souhaitées. Dans le chapitre suivant, le choix des entrées et la méthode de labellisation de la sortie sont justifiés.

3.7 Conclusion

Ce chapitre a présenté en détail un ensemble d'approches pour un système de localisation adapté au contexte de navigation pour un véhicule autonome. Ces méthodes ont été détaillées sous différentes sections, afin de mettre en évidence chaque contribution proposée. En premier lieu, un schéma illustratif d'un formalisme globale multi-objectives a été présenté. C'est un formalisme qui répond à des exigences opérationnelles d'une fonction de localisation telles que ; la sûreté, la précision et la disponibilité, dont certaines présentent un aspect antagoniste tel que la sûreté et la disponibilité. Pour répondre à ces exigences, cette étude a proposé des solutions mutli-niveaux :

- Une fusion de données multi-capteurs
- La détection des défauts et la prise de décision
- L'isolation des défauts

Pour augmenter la précision et la disponibilité du système, nous avons proposé la fusion des données brutes GNSS, IMU et les données odométriques. D'abord, nous avons présenté le modèle d'évolution du filtre d'information non linéaire. Ce modèle est basé principalement

sur la navigation inertielle qui détermine la position du récepteur à partir des mesures de l'accélération et de la vitesse angulaire. Puis, le modèle de mesures basé sur les pseudo-distances GNSS et les données odométriques. Cependant, en utilisant les systèmes GNSS une difficulté particulière due à ce choix doit être considérée : il faut être capable de détecter des défauts en considérant plusieurs facteurs tel que le changement brusque du contexte de navigation et les exigences opérationnelles à chaque instant. Or, les approches standard supposent couramment que l'environnement est statique et qu'il existe qu'une seule exigence à satisfaire la fois (améliorer la précision au détriment de la sûreté et inversement). Dans cette mémoire, le choix a été donc d'intégrer les méthodes l'apprentissage en vue d'adapter la couche de diagnostic au contexte environnemental de navigation tout en assurant un compromis entre les exigences opérationnelles.

Tout d'abord, nous avons présenté le concept d'adaptativité. Ensuite, nous avons proposé l'approche détaillée de diagnostic adaptative à l'environnement qui permet de localiser précisément le véhicule tout en gérant des défauts GNSS soudains pouvant affecter l'intégrité du système de localisation. Cette approche a été développée en deux parties : une partie théorique présentée dans le chapitre 2 afin de tirer profit des outils informationnels et une partie orientée données basée sur les algorithmes d'apprentissage.

En premier lieu, nous avons proposé un résidu paramétré basé sur la divergence de Rényi (α -RD). La particularité de cette divergence consiste à établir un lien entre les résidus et l'environnement par le biais de son paramètre α . Ce paramètre a un impact important sur le résidu, il rétablit l'équilibre de confiance entre les matrices de covariance de prédiction et de correction dans différents cas. Pour la sélection de ce paramètre, deux solutions ont été proposées. La première est une fonction sigmoïde généralisée, qui prend en compte le rapport entre la matrice de covariances d'étape de prédiction et la matrices de covariances de l'étape de correction du filtre d'intégration. La deuxième est une approche d'apprentissage qui prend en compte les informations pertinentes qui caractérisent les signaux GNSS.

En deuxième lieu, le critère de Rényi (α -Rc) a été proposé pour un seuillage adaptatif. Le but de ce critère est de générer un seuil optimal dont le dépassement indique la présence d'un défaut. En outre, le calcul du α -Rc est basée sur un paramètre prépondérant pour une prise de décision optimisée, l'estimation de la probabilité P_0 . Dans cette étude ce paramètre a été estimé par un réseau de neurones profond en vue d'assurer un compromis entre la sûreté et la disponibilité. Enfin, une conception hiérarchique de l'UIO a été brièvement présenté pour l'isolation de défauts.

Afin de démontrer l'intérêt et valider certains volets du travail réalisé, le chapitre suivant présente la mise en œuvre expérimentale des approches proposées sur des données réelles via l'utilisation d'un véhicule expérimental robotisé de type Renault Zoé.

Chapitre 4

Validation de l'approche proposée : entre données réelles et jumeau numérique vers une convergence nécessaire

Afin de valider la localisation adaptive en fonction du contexte, ce chapitre est dédié à la mise en œuvre expérimentale et l'analyse des résultats des approches proposées. Dans une première partie, pour détecter les mesures GNSS erronées, le processus de paramétrisation d'un résidu basée sur hybridation d'une approche informationnelle et d'une technique d'apprentissage est détaillée. Ensuite, les résultats d'estimation du paramètre α sont présentés. les performances de l'approche proposée sont comparées à ceux d'une approche de diagnostic basée sur un valeur du paramètre α fixe (la divergence KLD). En deuxième partie, pour prendre la décision concernant ces mesures, les résultats de la méthode de seuillage basée sur une fonction d'optimisation renforcée par une approche apprentissage profond est présentée.

4.1 Introduction

Dans le chapitre précédent, la localisation multi-objectives d'un véhicule autonome a été étudiée avec une méthode de détection des défauts GNSS adaptive au contexte de navigation par apprentissage. Le concept d'adaptativité a été présenté. Ainsi, une étape clé pour la mise en œuvre d'une couche de diagnostic adaptée à l'environnement est la paramétrisation du résidu α -RD par le biais du paramètre α .

Ce chapitre commence par une présentation des moyens expérimentaux utilisés, leurs

installations et leurs configurations, pour effectuer les essais et les tests des algorithmes développés.

Par la suite, la nécessité d'alimenter les algorithmes d'apprentissage avec des données provenant d'un panel de situations à risque sera abordée, nous conduisant ainsi à un outil plutôt numérique. Cependant, nous avons adopté l'utilisation d'un jumeau numérique qui sera présenté dans ce chapitre.

En premier lieu, le processus expérimental du concept d'adaptativité par apprentissage sera détaillé sous 3 phases. Nous introduisons la collection des données, la sélection des entrées du réseau de neurones, le partitionnement (clustering) des données et la méthode de labellisation du paramètre α .

En second lieu, une présentation sera faite des résultats de l'algorithme de localisation, sur des trajectoires de tests dans différents contextes, avec l'approche de diagnostic adaptive par apprentissage présentée auparavant. Les résultats expérimentales montreront l'impact de la variation du paramètre α selon le contexte sur les performances du système en termes d'erreur de position. Ensuite, les résultats de l'approche proposée seront comparé avec une approche avec une valeur fixe du paramètre α .

Pour la prise de décision concernant les mesures aberrantes, l'algorithme de seuillage a été testé avec une fonction d'optimisation renforcée par un réseau de neurones profond. Enfin, l'analyse de ces résultats est discutée.

4.2 Mise en place expérimentale

Cette section présente une brève introduction sur le type de données et les principaux outils utilisés lors des tests expérimentaux.

L'ensemble des tests expérimentaux est réalisé à l'aide d'un véhicule robotisé de la gamme Renault Zoé pour l'aquisition des données réelles (voir figure 4.1). Ce véhicule est équipé avec des capteurs extéroceptifs, proprioceptifs et du matériel pour l'enregistrement des données et l'estimation d'une référence de positionnement. Ce matériel est complété par des suites logicielles nécessaires au traitement hors ligne des données enregistrées. Par la suite, les données réelles enregistrées seront exploiter pour tester et valider les algorithmes proposées, mais également pour alimenter l'entrée du jumeau numérique pour la génération des scénarios pour le processus d'apprentissage.

4.2.1 Équipements techniques

Le véhicule expérimental du laboratoire CRISAL est équipé d'un système Novatel Pwr-Pak7D qui fusionne le système GNSS, INS and les messages RTCM pour mesurer la position exacte du véhicule. Les mesures obtenues à partir des données en transit sur le bus de com-




FIGURE 4.1 – Véhicule de test équipé du matériel

munication Controller Area Network (CAN), tel que les capteurs de série : les odomètres, le gyromètre du lacet sont accessibles via une prise dédiée. Les données odométriques seront enregistrées à une fréquence de 100 Hz. Le véhicule est équipé également d'un ensemble de capteurs de localisation. Pour enregistrer la dynamique du véhicule, on utilise les données brutes de l'IMU OS3D-FG à une fréquence de 200 Hz. Les données brutes GNSS sont enregistrées par un récepteur Ublox M8P à une fréquence de 1 Hz. Cette partie matérielle est mise en œuvre sur un ordinateur Linux avec le système d'exploitation ROS (Robot Operating System), qui assure l'enregistrement de l'ensemble des données via le format rosbag. Comme chaque capteur a son propre repère, toutes les données sont transformées dans le repère principal attaché au véhicule à l'instant $t = 0$. La figure 4.2 présente un schéma de quelques équipements embarqués sur le véhicule et leurs caractéristiques dans le tableau 4.1.

4.2.2 Les trajectoires réelles

Les équipements mentionnés précédemment sont utilisés dans différentes trajectoires pour la collecte de données et les tests expérimentaux. Nous présentons une vue réelle satellitaire en 2D, à partir du logiciel Google Earth, La figure 4.3 illustre un ensemble de trajectoires réelles utilisées de différents contextes de navigation. Pour générer les distributions avec et sans défauts, la collecte des données statistiques a été réalisée avec les mêmes équipements et la même configuration pour les six trajectoires (C1, C2, C3, C4, C5 et C6).

Le tableau suivant 4.2 fournit des informations détaillées pour les trajectoires utilisées.

Tester et valider les approches de diagnostic destinées à une application présentant un aspect sécuritaire important, telle qu'un véhicule autonome, il est nécessaire d'avoir à disposition un grand volume de données avec défauts sans endommager le prototype et sans risquer la sécurité de l'utilisateur. Cette nécessité nous conduit rapidement vers les

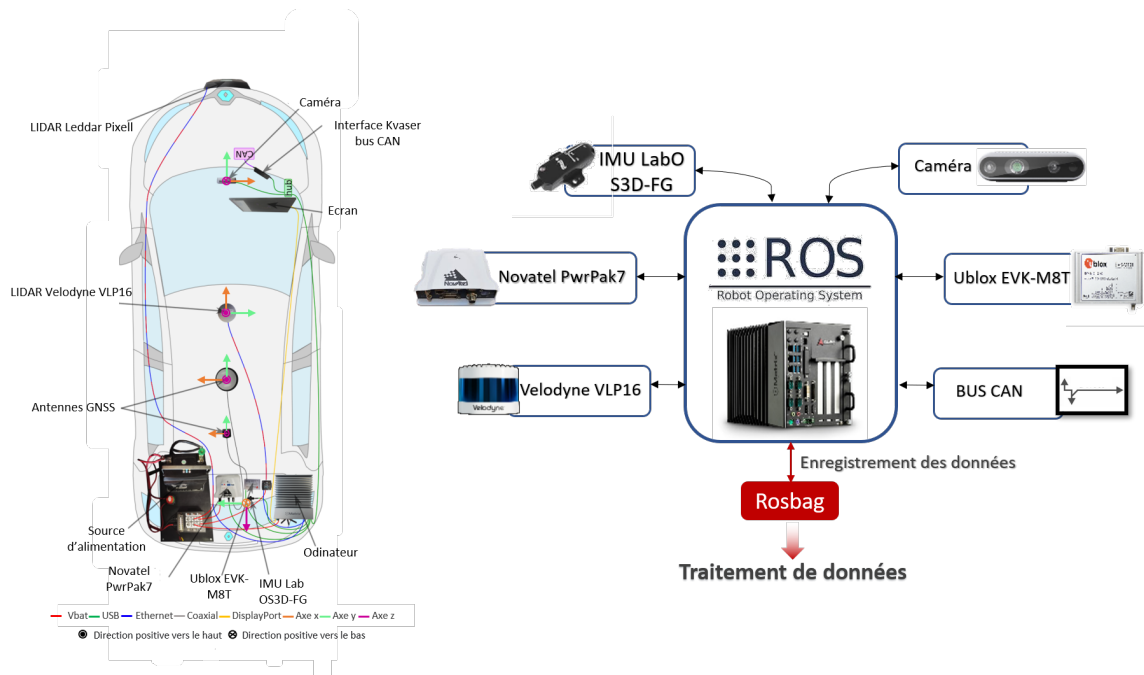


FIGURE 4.2 – Schéma des équipements présents dans le véhicule de test pour l'enregistrement des données réelles

simulateurs de systèmes, vu leur capacité de produire facilement d'importantes quantités de données. Ces modèles de simulation aident les utilisateurs à évaluer la performance réelle du système. Bien que les simulateurs habituels basés sur un scénario de test prédéfini soient toujours d'un grand intérêt, il est nécessaire d'intégrer ces simulations dans un environnement de test plus large. Il est nécessaire d'intégrer un simulateur de véhicule dont les utilisateurs/conducteurs prennent potentiellement le contrôle et la décision en temps réel.

4.3 Le jumeau numérique : Vers des outils numériques fidèles pour une validation accélérée de l'approche développée

Aujourd'hui, avec le progrès de l'intelligence artificielle dans le domaine des véhicules autonomes, les expérimentations industrielles et scientifiques évoluent d'une manière significative pour tester et valider les méthodes de localisation basées sur les techniques d'apprentissage. Cependant, il reste de nombreux défis à relever pour généraliser et commercialiser ces méthodes. Pour atteindre une performance acceptable, ces techniques nécessitent un volume important de données pour anticiper le comportement du système et prendre les bonnes décisions.

4.3. LE JUMEAU NUMÉRIQUE : VERS DES OUTILS NUMÉRIQUES FIDÈLES POUR UNE VALIDATION ACCÉLÉRÉE DE L'APPROCHE DÉVELOPPÉE

Technologie	Caractéristiques	ROS
 <p>Novatel oem7</p>	<ul style="list-style-type: none"> • Données brutes GNSS, cap, filtre de kalman (IMU+GPS) • Précision : RTK : 1 cm + 1 ppm 	<ul style="list-style-type: none"> • Fréquence : 20 Hz • /gps/fix/novatel/oem7/bestpos • /novatel/oem7 /oem7 raw
 <p>Ublox-F9P</p>	<ul style="list-style-type: none"> • Précision en RTK : • < 1cm avec une station de base jusqu'à 35km 	<ul style="list-style-type: none"> • Fréquence : 1Hz • /f9p/fix
 <p>Ublox-M8T</p>	<ul style="list-style-type: none"> • Précision de position : 2.0 m • Mesures brutes GNSS 	<ul style="list-style-type: none"> • Fréquence : 1Hz • /m8t/fix
 <p>IMU OS3D-FG</p>	<ul style="list-style-type: none"> • Précision : • Gyroscopes : 500 ppm • Accéléromètres : 700ppm 	<ul style="list-style-type: none"> • Fréquence : 200Hz • /imu_os3d/imu
 <p>Kvaser</p>	<ul style="list-style-type: none"> • Informations du bus CAN (odométrie, vitesse des roues...) 	<ul style="list-style-type: none"> • Fréquence : 100Hz par message • /writer2/can_tx • /writer2/can_rx

TABLE 4.1 – Les spécifications de quelques équipements utilisés

Généralement, la simulation est l'une des solutions principales pour tester la fiabilité de ces algorithmes. En effectuant des millions de kilomètres de roulage virtuellement on peut réduire considérablement le coût de développement du véhicule autonome. En plus du

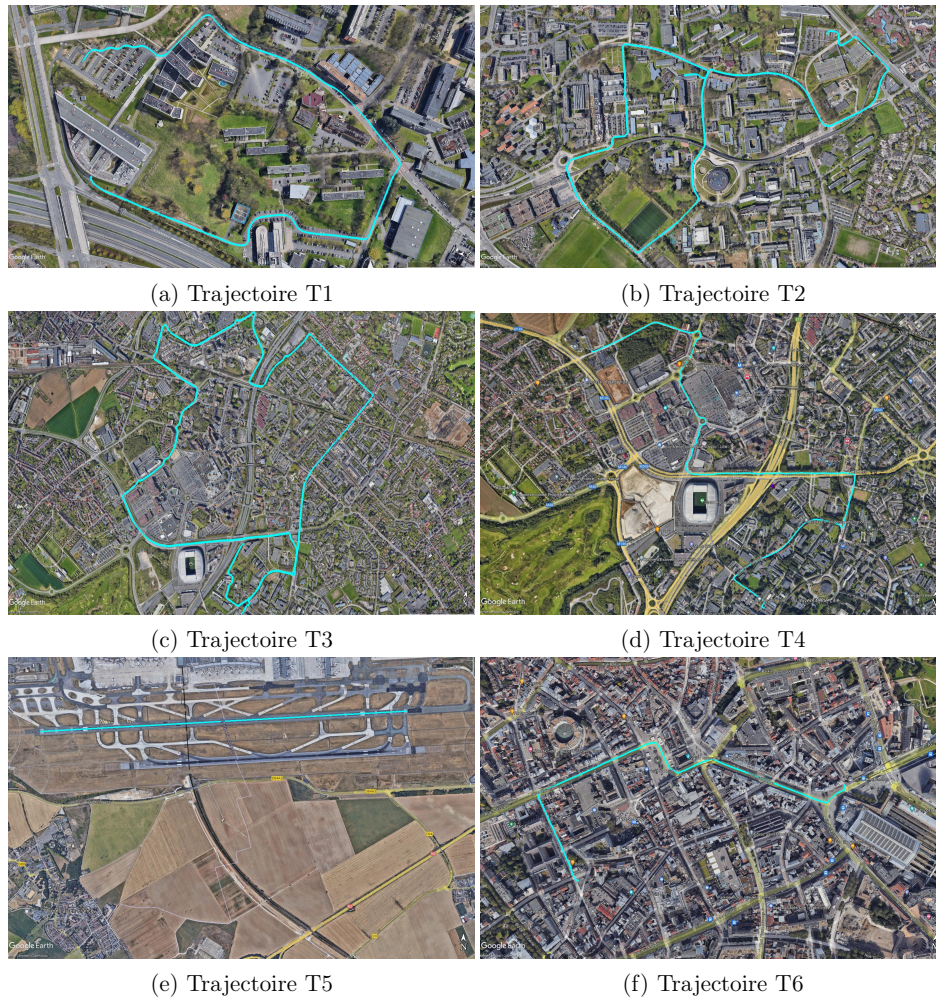


FIGURE 4.3 – Vue satellitaire des trajectoires de références

TABLE 4.2 – Les caractéristiques des trajectoires utilisées

Indice trajectoire	Distance parcourue
T1	1134.2 meters
T2	3444.6 meters
T3	9844.71 meters
T4	12448.55 meters
T5	6461.20 meters
T6	3520.90 meters

gain de temps et d'argent, la simulation numérique permet de réduire considérablement le risque d'accident pour les utilisateurs. Cependant, la simulation ordinaire présente des limites importantes pour les essais dans différents environnements. Elle ne peut pas prédire comment le véhicule réagirait à des scénarios complexes ou à des changements de circonstances.

Ces dernières années, la simulation a atteint un progrès potentiel grâce à un concept appelé « jumeau numérique » en anglais « digital twin ». Par définition [16], un jumeau numérique

4.3. LE JUMENTA NUMÉRIQUE : VERS DES OUTILS NUMÉRIQUES FIDÈLES POUR UNE VALIDATION ACCÉLÉRÉE DE L'APPROCHE DÉVELOPPÉE

est "une représentation virtuelle dynamique d'un objet physique ou d'un système tout au long de son cycle de vie, utilisant des données en temps réel pour permettre la compréhension, l'apprentissage et le raisonnement". C'est un concept qui relie un système physique (un avion, une machine, un véhicule,...) à un modèle numérique, permettant à l'utilisateur de prendre des décisions dans un environnement contrôlé et sans risque. Cependant, cette technologie génère et traite un grand volume de données sur le système en temps réel [180], ce qui offre l'opportunité de tester et valider la performance du système et de prendre des décisions dans un environnement numérique sans risque permettant de :

- Disposer d'un volume important de données avec la possibilité d'injecter des scénarios de défauts capteurs pour tester et valider les méthodes de diagnostic sans endommager le prototype et sans risquer la sécurité de l'utilisateur.
- Bâtir un modèle représentatif de la réalité (allant d'un niveau de précision de 95% à 99%) qui prend en compte les sources de variabilités internes et externes.
- Réduire des coûts d'investissement et d'exploitation du matériel en prenant les bonnes décisions au bon moment.
- Maximiser la disponibilité du système.
- Développer et générer des scénarios et expérimentation.
- Prédire la performance du système entier en quelques minutes.




FIGURE 4.4 – Le jumeau numérique pour la génération et l'enregistrement des données simulées GNSS

Dans ce travail, le jumeau numérique constitue l'une des sources principales de données pour tester et valider l'approche proposée dans le chapitre 3. Cette solution est composée de

deux parties principales : un simulateur/émulateur de signaux GNSS couplé à un simulateur de conduite dans un environnement virtuel. L'un des principaux avantages de cette technologie est la capacité d'intégrer des données de localisation réelles fournies par un récepteur GNSS réel dans un environnement virtuel. Il peut également simuler d'autres capteurs de localisation proprioceptifs et extéroceptifs comme encodeurs, IMU, Lidar....

Le jumeau numérique développé au sein du laboratoire CRISAL est présenté dans la figure 4.4, où le simulateur/émulateur GNSS (Stella NGC), est couplé avec le simulateur de conduite dans un environnement virtuel CARLA par le biais d'une connexion TCP/IP. Le simulateur CARLA a été entièrement conçu pour faciliter le développement et la validation des systèmes de conduite autonome. En plus des protocoles open-source, CARLA fournit des ressources numériques ouvertes (plans urbains, bâtiments, véhicules) qui ont été créées à cette fin et peuvent être utilisées librement. La plateforme de simulation prend en charge la spécification flexible des suites de capteurs, des conditions environnementales, le contrôle complet de tous les acteurs statiques et dynamiques et la génération de cartes. Dans ce travail, on se focalise sur l'acquisition et la génération des mesures GNSS en utilisant le simulateur/émulateur Stella NGC.

4.4 Stella NGC

Stella NGC est un simulateur/émulateur des signaux GNSS développé par la société M3 Systems et utilisé dans le cadre du projet ANR LOCSP No 2019-CE22-0011. Ce logiciel est capable de :

- Simuler toutes les constellations GNSS (GPS, Galileo, GLONASS, Beidou)
- Reproduire les signaux émis par les satellites de navigation et les signaux reçus à l'aide du récepteur GNSS réel dans une configuration en boucle fermée (voir figure 4.5).
- Emuler le mouvement du véhicule

Cet outil permet également de générer de multiples scénarios (des situations réelles) présentant des défauts GNSS réalistes, par l'injection de défauts avec des niveaux de gravité différents sur les mesures brutes GNSS pour alimenter les algorithmes d'apprentissage. Ces scénarios sont générés sans créer des situations de test dangereuses et sans endommager le véhicule réel. Ces trajectoires de scénarios peuvent être créées de manière continue en un temps très court pour la génération d'une base de données des mesures GNSS avec un nombre important de kilomètres, ce qui est difficile à faire dans un environnement réel. Cet outil permet également l'intégration d'un modèle IMU afin que des données GNSS et IMU cohérentes puissent être générées simultanément (par exemple, pour le test d'une solution de fusion de données GNSS/IMU).

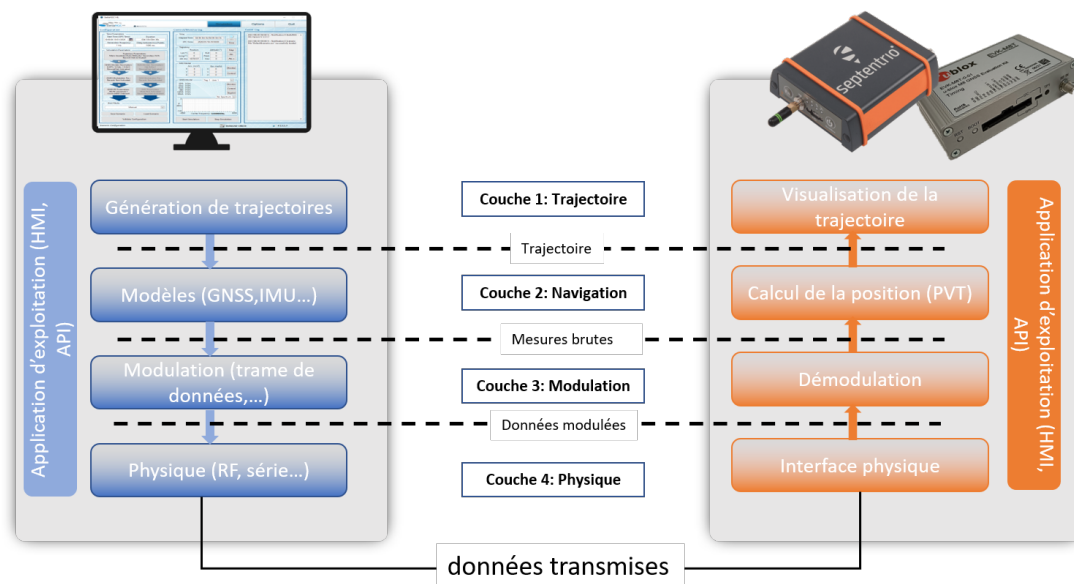


FIGURE 4.5 – Le principe de fonctionnement de Stella NGC en boucle fermée

La conception de ce simulateur/émulateur est basée sur 4 couches :

1. La couche trajectoire fournit la trajectoire à simuler.
2. La couche de navigation fournit les données brutes attendues susceptibles d'alimenter en temps réel un filtre de navigation pour la trajectoire simulée.
3. La couche de modulation fournit une représentation du signal tel que récupéré à l'extrémité de l'entrée d'un récepteur pour la trajectoire simulée, sous la forme d'échantillons numériques du signal analytique en bande de base pour le GNSS, et sous la forme de trames de données pour l'IMU.
4. La couche physique fournissant une représentation du signal GNSS tel que reçu au niveau du connecteur d'antenne, ou des données IMU au niveau du connecteur de liaison de données, pour la trajectoire testée.

4.5 Développement et résultats du concept d'adaptativité par apprentissage

Afin de tester et de valider l'approche proposée, les tests sont appliquées à l'aide de trois étapes principales comme présenter sur la figure 4.6 :

- **Phase 1** : La collection des données
- **Phase 2** : l'extraction des caractéristiques, le clustering et l'analyse des données GNSS

- Phase 3 : L'étiquetage du paramètre α




FIGURE 4.6 – Illustration de la partie expérimentale de l'approche proposée

4.5.1 La collection des données

Afin de collecter un volume important de données GNSS pour alimenter le réseau de neurones, des scénarios élaborés avec une connaissance approfondie des instants et du type de défaut doivent être employés. Cependant, en raison des défauts imprévisibles (un nombre infini de types de défauts) qui peuvent être reçus pendant la réception des signaux GNSS,

les données collectées à partir de la trajectoire réelle doivent être exemptes de défauts par le simulateur. Pour cette raison, le simulateur prend comme entrée des trajectoires réelle ou simulés (sous format KML) avec une possibilité d'intégrer la dynamique du véhicule. A partir des informations fournies par le fichier KML, il génère les positions des satellites GNSS à partir des éphémérides (importer à partir du fichier de navigation de l'*Institut national de l'information géographique et forestière (IGN)*) et simule les signaux à recevoir par le récepteur GNSS, à partir des satellites visibles (nombre maximale : 8 satellites) à la date et l'heure définies par l'utilisateur. Par conséquent, des trajectoire de référence "sans défaut" sont générées, et un enregistrement des données brutes de ces trajectoires est réalisé à l'aide d'un récepteur GNSS.

Ainsi, pour générer un volume important de données avec et sans défauts, un générateur de scénarios a été développé afin d'automatiser les scénarios entachés de défauts. Les trajectoires sans défauts sont utilisées comme entrée pour le générateur de scénarios pour générer un volume important de scénarios, où on injecte un ou une combinaison de différents **types de défauts** au niveau des mesures GNSS à des périodes spécifiques, tels que :

- 1) Les erreurs troposphériques
- 2) Les erreurs ionosphériques
- 3) Les NLOS
- 4) Le biais d'horloge du récepteur
- 5) La diminution de l'intensité du signal
- 6) Le masquage satellitaire
- 7) La suppression des signaux de certains satellites

Concernant le masquage satellitaire, la cartographie à source ouverte « OpenStreetMap » a été utilisée en vue d'intégrer une source de données supplémentaire au simulateur/émulateur pour améliorer nos connaissances sur le contexte de navigation et renforcer l'aspect réaliste des scénarios.

Dans ce contexte, un profil réaliste d'un masquage satellitaire (l'élévations des satellites en fonction d'azimuth) est intégré dans Stella NGC à partir des données fournies par cette carte comme la hauteur des bâtiments, le nombre des étages, le type des matériaux des bâtiments, les zones boisées, les tunnels et les ponts. Pour avoir toutes ces informations nous avons utilisé une bibliothèque Python nommée « Pyrosm ». Elle facilite l'extraction de divers ensembles de données à partir d'OpenStreetMap, notamment les réseaux routiers, les bâtiments, l'occupation des sols, les éléments naturels, les limites administratives et bien plus encore. Des requêtes entièrement personnalisées sont prises en charge, ce qui permet d'analyser tout type de données provenant de la carte.

La figure 4.7.(a) et 4.7.(b) montrent une vue polaire du profil de masquage et la surface

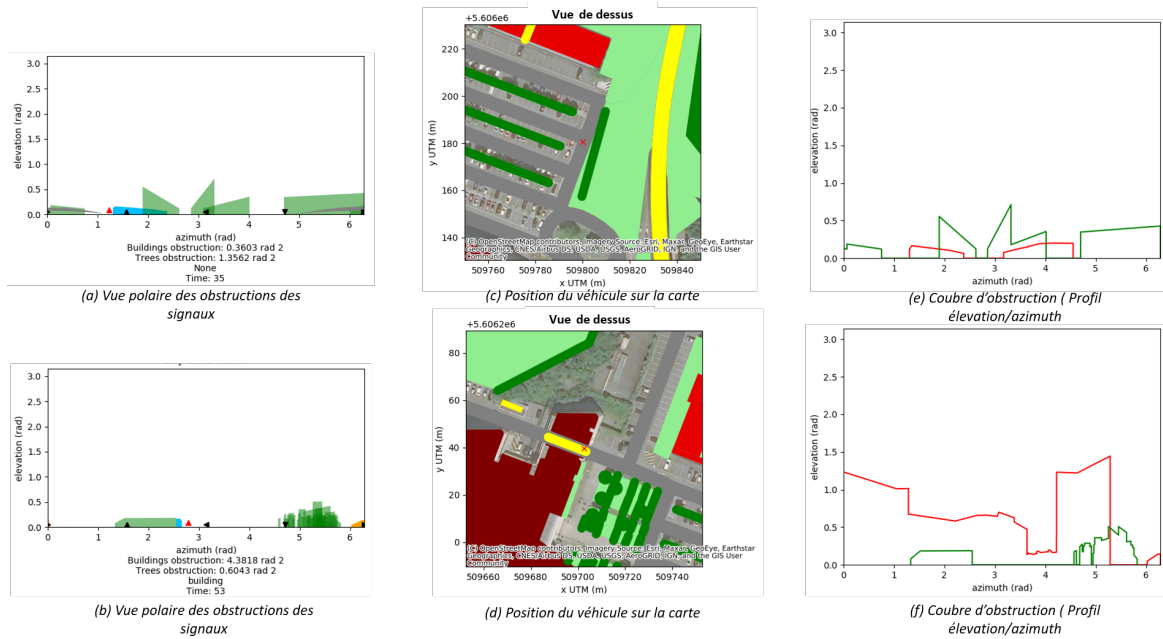


FIGURE 4.7 – Masquage satellitaire des signaux GNSS pour la trajectoire T4 à l'aide d'OpenStreetMap

masquée par des bâtiments et des arbres. Les bâtiments sont représentés par des polygones. La couleur bâtiments varie selon le type de matériaux du bâtiment et le nombre d'étage. La direction du véhicule est indiquée par la flèche rouge correspond au Nord. La figure 4.7.(c) et 4.7.(d) présentent la position dynamique du véhicule sur la carte. Sur la Fig 4.7.(d), lors du passage du véhicule au dessous d'un bâtiment le masquage est plus important (voir figure 4.7.(f)).

Après la génération des scénarios avec les défauts, la simulation de ces scénarios est lancée d'une manière successive et l'enregistrement des mesures GNSS est réalisé. Au total 1000 scénarios pour chaque trajectoire ont été simulés ce qui vaut plus que 60 000 km.

La figure 4.8 montre un exemple d'une trajectoire réelle intégrée dans Stella NGC sans défaut en la comparant avec la trajectoire issue de l'acquisition réelle, et la même trajectoire entachée de défauts dont les caractéristiques sont détaillées dans le tableau suivant :




FIGURE 4.8 – (a) Un scénario nominal (sans défaut) de la trajectoire T4 , (b), (c) et (d) les scénarios avec défauts

Scénarios	Trajectoire	Nombre de satellites	Nombre de défauts	Type de défauts	Détails
Scénario 1	T1	8	2	5) 7)	-15dB 2 sat
Scénario 2	T1	8	1	3)	biais doppler biais phase
Scénario 3	T1	8	2	5) 6)	-20dB masque de 40°
⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮
Scénario n	T1	8	n	n	n

TABLE 4.3 – Extrait des scénarios de défauts pour la trajectoire T4

4.5.2 Identification des entrées du réseau de neurones

La sélection des données est la première étape principale pour acquérir les connaissances souhaitées sur l'environnement de l'utilisateur et établir un lien entre entrées et sortie du réseau de neurones. Dans ce contexte, après la collecte d'une base de données volumineuse à partir des données acquises au cours des campagnes d'acquisition réelles et simulées/émulées. Ces données sont analysées par **goGPS** : C'est logiciel de positionnement sous l'interface MATLAB conçu pour le traitement des observations GNSS [76]. Ce logiciel peut traiter les données collectées par n'importe quel récepteur, mais se concentre sur le traitement des observations des récepteurs à faible coût. Il traite les observations d'entrée en lisant les fichiers RINEX standard. Par la suite, ce logiciel met en œuvre plusieurs algorithmes pour analyser les données et produire des solutions époque (instant) par époque par une méthode des moindres carrés, ou des solutions multi-époques par un filtrage de Kalman. Dans cette étude, nous extrayons les données qui permettent d'avoir une idée sur la qualité des mesures GNSS en se référant aux paramètres caractéristiques pertinentes des signaux GNSS, comme les informations des satellites (élévation des satellites) et les informations sur la propagation des signaux (C/N_0). Des recherches antérieures ont montré l'efficacité de ces données dans un environnement urbain dynamique, généralement pour la classification des signaux reçus en trajet direct (LOS) et trajets indirects (NLOS) [213]. Afin d'appliquer le concept d'adaptativité par apprentissage, notre jeu de données d'entrée est composé d'un vecteur de 7 paramètres :

- *Le nombre de satellites visibles* : le nombre de satellites disponibles à un instant est l'un des indicateurs principales de la qualité des observations en lien avec la position et qui a un impact direct sur la qualité du signal satellitaire [159]. Par exemple, dans un environnement comportant des perturbations au niveau de la propagation

des signaux, le nombre des satellites visibles peut largement varier. Pour pouvoir se positionner en 3D, un minimum de 4 satellites visibles doit être atteint. Ce critère est fortement lié à un autre critère caractérisant la précision du positionnement : le DOP.

- Le positionnement des satellites : l'effet de la géométrie des satellites sur les erreurs de positionnement est appelé DOP (pour Dilution of Precision ou affaiblissement de la précision). La précision du positionnement GNSS dépend généralement de ce critère. Il quantifie la bonne répartition des satellites à un instant donné. Plus les satellites seront écartés les uns des autres, meilleur sera le DOP. En effet, la position de l'utilisateur est obtenue par trilatération qui consiste à chercher le point d'intersection de sphères dont les centres sont les satellites et les rayons sont les pseudodistances (voir chapitre 2 section 2.2.1). Quand les satellites sont éloignés les uns des autres, alors la superficie de l'aire d'intersection, qui correspond à l'incertitude sur la position, est moindre que lorsque les satellites sont proches ou alignés. Dans un environnement urbain dense, une valeur DOP élevée signifie souvent une grande probabilité d'effet multi-trajets et de réception NLOS.
- L'élévation des satellites : L'élévation définit l'angle entre le satellite et l'horizon dans le plan vertical. La valeur de l'élévation est comprise entre 0 et 90°. Certains récepteurs ne considèrent que les satellites ayant une élévation supérieure à 10° car les signaux provenant de satellites bas en élévation subissent généralement des perturbations de propagation importantes liées à une traversée de l'atmosphère plus longue ou encore à une probabilité de réflexion plus élevée. En général, le signal satellitaire provenant de l'angle d'élévation le plus élevé est moins susceptible d'être bloqué et réfléchi par un bâtiment. En fonction de la hauteur et de la répartition des bâtiments, les signaux à élévation forte peuvent devenir des NLOS, et les signaux à élévation faible peuvent devenir des NLOS. Néanmoins, l'angle d'élévation reste un indice caractéristique important pour distinguer les signaux NLOS.
- Le rapport signal/bruit (C/N_0) : Le rapport entre la puissance du signal et la puissance du bruit est une information importante pour toute application des GNSS. La force du signal peut être une bonne indication de la qualité du signal reçu. Dans un environnement complexe, les réflexions ou diffractions des signaux GNSS atténuent le signal et augmentent le bruit. Ces perturbations impactent donc sa force en l'affaiblissant. La mesure C/N_0 est couramment utilisée comme paramètre pour réduire les effets multi-trajets. Il a été prouvé que la pondération basée sur le rapport C/N_0 pour la précision du positionnement est optimale par rapport à la pondération

basée sur l'élévation. [114].

- Le code minus carrier (CMC) : afin de déterminer les erreurs fournies par une mesure du GNSS dans une zone urbaine dense, en particulier, d'estimer les effets de la propagation par trajets multiples, nous avons besoin de disposer de deux types de mesures de portée fournies par le GNSS, appelées mesures de code et mesures de phase de la porteuse, et d'une analyse de la différence entre ces deux mesures, appelée "code minus carrier" [6], les chercheurs prouvent qu'elle peut être un paramètre permettant d'atténuer les effets de la propagation par trajets multiples grâce à sa capacité à estimer avec précision la composante de retard ionosphérique, une estimation de la composante de bruit du multi-trajets et du récepteur [14], [103].
- Les covariances : la moyenne, la trace et le déterminant des matrices de variances-covariances des étapes de prédiction P_{Pred} , et de correction P_{Corr} du filtre de fusion. Elles permettent, d'intégrer les tendances de fond par l'étude des variations temporelles.

Ainsi, les caractéristiques des données GNSS sélectionnés constitueront les entrées du réseau de neurones. L'objectif de ce réseau consiste à approximer une fonction de régression afin d'établir une relation entre les entrées pertinentes et la sortie souhaitée du réseau. Dans ce travail, on utilise un algorithme d'apprentissage supervisé. Cependant, il est indispensable d'étiqueter au préalable ces données, c'est-à-dire d'attribuer à chaque donnée une valeur du paramètre α . Dans la prochaine section, nous présentons la technique développée pour labellisation les données par apprentissage automatique.

4.5.3 Le clustering des données par caractéristiques

Après avoir défini le jeu de données, celles-ci sont regroupées par caractéristique similaires à l'aide d'un algorithme d'apprentissage automatique appelé "*K-means*". Ce dernier est une méthode de partitionnement de données faisant appel à un algorithme non supervisé de clustering non hiérarchique. Cette méthode permet de regrouper en K clusters (groupes) distincts les observations du jeu de données. Ainsi les données à caractéristiques similaires se retrouveront dans un même cluster.

La première étape consiste à sélectionner k centroïdes, où k est égal au nombre de clusters. Les centroïdes sont des points de données représentant le centre d'un cluster. Pour sélectionner le nombre approprié de clusters, le coefficient de silhouette est employée [43]. C'est une mesure d'évaluation pour décider du nombre de clusters à établir à partir des données. Il mesure la similarité d'un point de données au sein d'un cluster (cohésion) par rapport aux autres clusters (séparation). L'objectif de cette mesure :

- Sélectionner une échelle de valeurs de k (1 à 10) la valeur la plus approprié.
- Tracer le coefficient de silhouette pour chaque valeur de k

Ce coefficient est calculé pour chaque échantillon et la formule est la suivante :

$$\text{Coefficient de silhouette} = \frac{(x - y)}{\max(x, y)} \quad (4.1)$$

Où, y est la distance moyenne entre les clusters : distance moyenne par rapport aux autres échantillons du même cluster. x représente la distance moyenne entre les clusters les plus proches, c'est-à-dire la distance moyenne par rapport aux échantillons du cluster le plus proche.

Ce coefficient est compris entre $[-1, 1]$. Une valeur proche de 1 implique que l'instance est proche de son cluster et fait partie du bon cluster. Alors qu'une valeur proche de -1 signifie que échantillon est affectée au mauvais cluster. Le figure 4.9 montre que les valeurs de k de




FIGURE 4.9 – Résultat de l'algorithme de k-means pour le partitionnement des données : (a) Coefficient de silhouette en fonction des clusters étiquetés (b) Coefficient de silhouette en fonction du nombre de clusters sélectionnés k

2, 3, 5 et 6 sont un mauvais choix pour les données en raison de la présence de clusters avec des scores de silhouette inférieurs à la moyenne. Le nombre le plus approprié pour notre jeu de données est 4.

Il est à noter que l'épaisseur du tracé de la silhouette permet également de visualiser la taille de la classe.

Après avoir sélectionné le nombre approprié de clusters, l'élément principal de l'algorithme fonctionne par un processus en deux étapes appelé '*expectation-maximization*' [89]. La première étape attribue chaque point de données à son centroïde le plus proche. Ensuite, l'étape de maximisation calcule la moyenne de tous les points pour chaque groupe et définit le nouveau centroïde. L'algorithme *k - means* est présenté ci-dessous : En se basant sur

Algorithm 2: L'algorithme de K-means

```

Spécifier le nombre  $k$  à attribuer par l'analyse de silhouette.
Initialiser les  $k$  centroïdes.
while true do
    Expectation : affecter chaque point au centroïde le plus proche
    Maximization : calculer le nouveau centroïde (la moyenne) pour chaque
    cluster
    if La position du centroïde ne change pas then
        | break
    end
end

```

les caractéristiques des signaux GNSS reçus, les contextes environnementaux sont catégorisés comme suit : ciel ouvert, environnements sous-urbains, urbains et couverts.

4.5.4 La labellisation du paramètre α

En apprentissage profond, les problèmes rencontrés s'inscrivent dans différents paradigmes. Le plus étudié en apprentissage supervisé est certainement la labellisation appelé également étiquetage [186]. Son objectif est d'associer à un objet, décrit par un vecteur de variables attributs, un unique concept d'intérêt (variable cible) que l'on définit comme '**label**'. Cependant, avant d'associer à chaque donnée d'un cluster un label (une valeur d' α), une caractérisation des résidus doit être effectuée. En premier lieu, la génération des résidus pour chaque cluster avec et sans défauts. En considérant que les époques des défauts sont déjà labélisées par le générateur de scénarios, les fonctions de densité de probabilité sont créés pour les cas avec et sans défaut(s) (voir figure 4.10). Dans ce cadre, le processus de labellisation s'active. D'abord, un panel de valeur de α $[0, 1[$ sera appliqué à chaque cluster pour sélectionner le résidu le plus sensible aux défauts pour chaque cluster par l'algorithme *IoU*. Rappelons que c'est une mesure d'évaluation du chevauchement entre les distributions avec et sans défaut(s). Cet algorithme prend en entrée les deux distributions, comme son nom l'indique, il calcule le rapport de l'intersection et de l'union des deux. Cette mesure est défini par un score qui varit de $[0, 1]$, plus que la valeur de score s'approche de 0, moins on a du chevauchement entre les distributions avec et sans défaut(s). Le tableau 4.4 montre les résultats de labellisation du paramètre α pour les données GNSS basée sur le score de l'algorithme *IoU*. On constate que pour le premier cluster ; la valeur du paramètre α qui minimise le chevauchement entre les deux distributions c'est $\alpha=0.2$, alors que pour le cluster 4 la valeur la plus appropriée c'est $\alpha=0.8$.

$$IoU = \frac{Intersection}{Union} \quad (4.2)$$

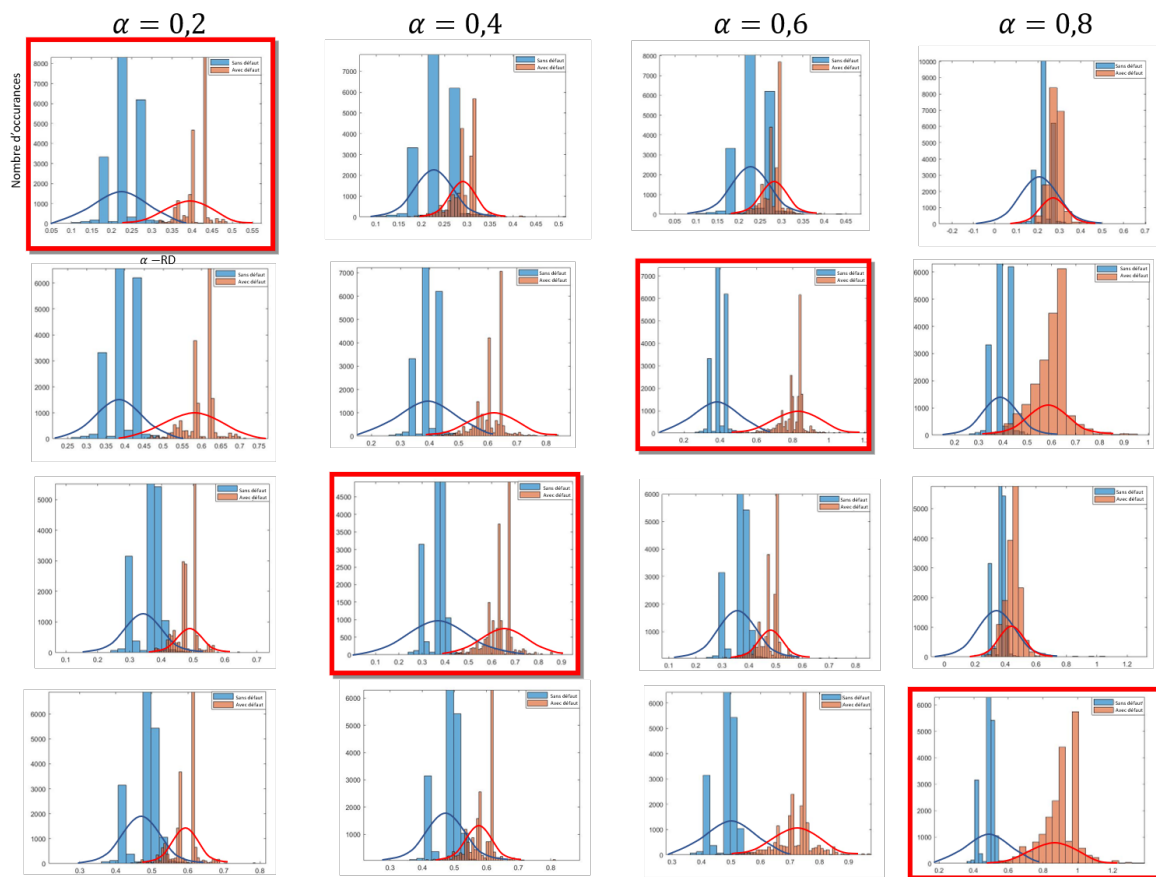


FIGURE 4.10 – Les fonctions de densité de probabilité des résidus α -RD dans les cas « sans » et « avec » défaut pour chaque cluster pour différentes valeurs d' α

Clusters \ α	$\alpha=0.2$	$\alpha=0.4$	$\alpha=0.6$	$\alpha=0.8$
	Cluster 1	0.2660	0.55480	0.67488
Cluster 2	0.36411	0.42746	0.15525	0.54872
Cluster 3	0.28755	0.19112	0.51688	0.87549
Cluster 4	0.32521	0.52366	0.27219	0.18540

TABLE 4.4 – Résultats de la labellisation de α basée sur le score de l'IoU pour chaque cluster

4.5.5 Analyse des résultats

Après avoir collecter et labelliser les données, le processus d'apprentissage peut débuter, où les données sont divisées en 2 groupes de données « les données d'entraînement » et « les données de test et validation » (voir figure 4.11). Le premier groupe représente 70% de

l'ensemble de données. Ce groupe a pour fonction d'établir un lien (ou une fonction) entre les paramètres d'entrées et la sortie qui est la valeur d' α afin de synthétiser une relation fonctionnelle entre eux pour développer des modèles de régression pour l'estimation d' α . Le deuxième groupe représente 30% de l'ensemble de données. C'est l'étape d'évaluation de la performance et de l'efficacité du modèle d'apprentissage sélectionné à partir des données d'entraînement, puisque ce groupe contient des données qui n'ont jamais été vu par l'algorithme auparavant. Cependant, le choix de la topologie du réseau de neurones pour la sélection de la valeur d' α , est une étape essentielle pour la phase d'apprentissage. Dans ce contexte, la section suivante présente la topologie de réseau de neurones pour la paramétrisation d'un résidu α -RD, avec les résultats détaillés de l'approche proposée. Par la suite, nous détaillons l'architecture du réseau de neurones développé pour la partie de seuillage pour maximiser la détectabilité des défauts. Enfin, les résultats sont présentés et discutés.

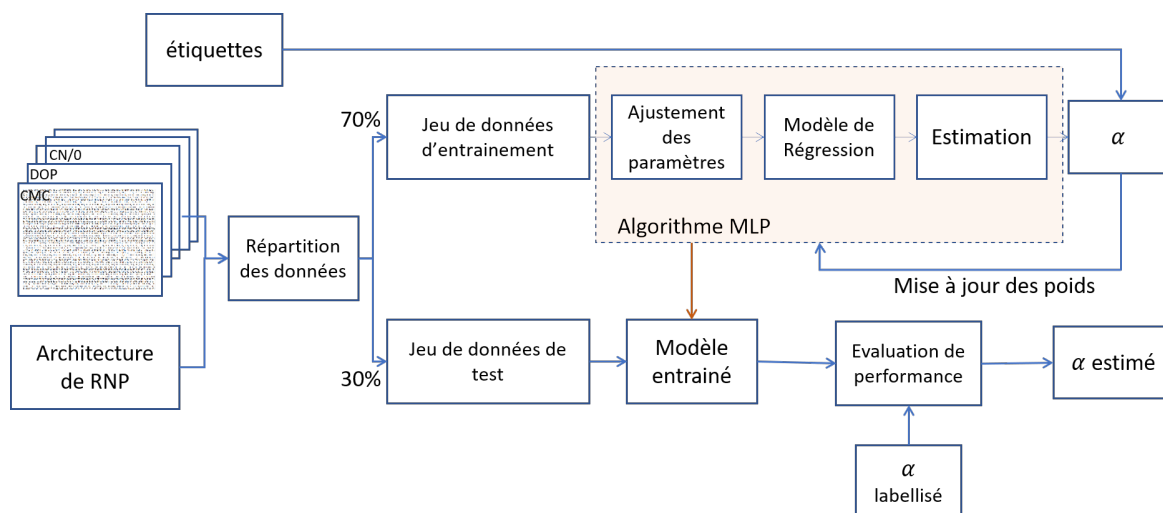


FIGURE 4.11 – Le processus d'apprentissage du paramètre α

Résultats de l'estimation du paramètre α par apprentissage

En raison de l'importance de la sûreté dans notre application, nous proposons une méthode de localisation adaptée au contexte de navigation basée sur un réseau de neurones profond. Cet outil sera performant pour aider l'utilisateur à sélectionner la valeur du paramètre α la plus appropriée. Par conséquent, en choisissant le résidu le plus sensible aux défauts en fonction du contexte de navigation, les résidus sont robustifiés, ce qui conduit à une augmentation du niveau d'intégrité afin d'améliorer la sécurité du système. La topologie du RNP choisie est le *perceptron multicouche (multilayer perceptron MLP)*. Ce réseau a été développé à l'aide de la bibliothèque de calcul numérique et d'apprentissage profond **TensorFlow** et **Keras** compatible avec le langage Python. Ce MLP comprend 3 parties : une couche d'entrée et une couche de sortie, et 4 couches intermédiaires cachées. Chaque couche

de réseaux de neurones comprend une séquence de neurones interconnectés les uns aux autres. Cette interconnexion est caractérisée par des paramètres appelés « poids » et « biais ». Un neurone désigne une unité de calcul qui applique une fonction d'activation non linéaire à ses entrées et transmet le résultat aux neurones de la couche suivante, puis la dernière couche cachée est connectée à la couche de sortie qui fournit le résultat de l'estimation du paramètre α (voir figure 4.12).

Dans l'équation 4.3, a_i , I_i , W_i , b_i désignent l'état d'activation de la sortie, l'entrée, le poids et le biais de la i -ième couche. Le calcul d'une couche de neurones entièrement connectée (en anglais Fully connected layer) est défini comme suit :

$$a_i = \sigma(I_i \cdot W_i + b_i) \quad (4.3)$$

Où σ est une fonction d'activation, elle a pour but d'ajuster et d'optimiser le réseau des neurones. Concernant la fonction d'activation, nous optons pour la fonction *Rectified Linear Unit (ReLU)* en raison de sa puissance en modélisation [58], son efficacité de calcul du coût pour les modèles de régression [160] et sa capacité à résoudre les problèmes comme le problème du vanishing gradient [3].

$$ReLU(x) = \max\{0, x\} \quad (4.4)$$

Son gradient est représenté comme :

$$\frac{d}{dx} ReLU(x) = \begin{cases} 0 & \text{if } x \leq 0 \\ 1 & \text{if } x > 0 \end{cases} \quad (4.5)$$

Dans l'apprentissage profond, la clé pour évaluer les performances du modèle, est la quantification de l'erreur d'apprentissage en utilisant les critères appropriés à l'application (modèle de régression) comme la fonction de coût (en anglais *Loss function*). Pour évaluer les performances de notre modèle d'apprentissage, deux fonctions de coût sont testées : l'erreur quadratique moyenne (MSE) et l'erreur moyenne absolue (MAE) [18]. La sélection de la fonction de coût appropriée est basée sur plusieurs variables du réseau : nombre de couches cachées, nombre de neurones dans chaque couche, le taux d'apprentissage, la taille des batches et nombre d'itérations pour estimer les erreurs d'apprentissage. La fonction qui présente le minimum global le plus petit est sélectionnée comme fonction de coût [191] La figure 4.13 montre que la MAE est la métrique d'erreur la mieux adaptée à notre application. L'erreur moyenne absolue *MAE* est définie comme suit :

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (4.6)$$

où \hat{y}_i est la valeur estimée d' α , y_i est la valeur labellisée d' α , n correspond au n -ième

4.5. DÉVELOPPEMENT ET RÉSULTATS DU CONCEPT D'ADAPTATIVITÉ PAR APPRENTISSAGE





FIGURE 4.12 – Architecture du réseau de neurones proposée « le perceptron multi-couche »

échantillon de données.



Couches Cachées \ Métrique d'erreur	CC1: 128	CC1:128 CC2:128	CC1: 128 CC2: 128 CC3: 128	CC1: 128 CC2: 128 CC3: 128 CC4: 128
MSE	1,2116	1,3658	0,7863	0,0648
MAE	0,8516	0,1038	0,0544	0,0134

FIGURE 4.13 – Choix de nombre de couches de neurones basé sur les métriques d'erreurs

Une partie du succès de nos réseaux neuronaux profonds multicouches peut être expliquée par la capacité de l'algorithme d'estimer et d'ajuster les poids du réseau à partir des données grâce à une méthode basée sur une fonction d'optimisation appelée 'la Rétropropagation'. Pour mettre à jour les poids de réseau itératifs basés sur les données d'entraînement, nous

proposons l'*Adam optimizer* [104] [216] qui utilise la *descente de gradient stochastique* (en anglais : *Stochastic Gradient Descent SGD*) comme fonction d'optimisation. Cette méthode s'est avérée efficace pour les problèmes de regression, comme en témoignent les travaux dans ([40] et [78]). Le principal avantage de cette méthode, consiste à calculer à partir des estimations des premier et deuxième moments des gradients, un taux d'apprentissage adaptatif individuel pour les différents paramètres.




FIGURE 4.14 – (a) Résultats de l'estimation du paramètre α par le réseau de neurones proposée, (b) résultats de l'évaluation du modèle d'apprentissage par une métrique d'erreur (l'erreur absolue moyenne)

La figure 4.14a montre les résultats de la performance du modèle sélectionné pour l'estimation de la valeur du paramètre α labellisée pour la trajectoire de test T1. Chaque valeur du paramètre α est sélectionnée en fonction des caractéristiques spécifiques du signal, tel que le nombre de satellites disponibles, les élévations, le HDOP, etc.

La figure 4.14b compare les performances du modèle d'entraînement au données de test. Ces résultats indiquent que le RNP développé fournit une estimation précise avec une MAE moyenne d'environ 0,01%.

Résultats et analyse au niveau de l'estimation de position

Pour tester et valider le concept d'adaptativité par apprentissage. En utilisant le NIF, les valeurs du paramètre α estimées par RNP sont intégrées dans la couche de diagnostic, dans l'optique de paramétrer le résidu basée sur la divergence de Rényi. Pour cela, une analyse du résidu avant la mise en œuvre de l'approche doit être effectuée. Dans la Figure 4.15, le résidu α -RD est calculé sans l'implémentation de la couche FDI. Sur l'ensemble de la trajectoire de test T1, une variation significative des valeurs de résidus est constatée, susceptible de signaler la présence de défauts.




FIGURE 4.15 – Résidus avant l’intégration de l’approche de FDI

La figure 4.16 montre l’impact de l’intégration de l’approche basée sur une hybridation modèle/données sur le résidu. Après la sélection de la valeur appropriée du paramètre α basée sur le RNP selon le contexte de navigation, le résidu α -RD est généré. Ensuite, le seuil optimisé (détaillé dans la section 3.6) est mis en œuvre pour décider des mesures erronées. Nous pouvons constater que l’amplitude du résidu a diminué et il présente un comportement plus régulier.




FIGURE 4.16 – Résidus avant et après l’intégration de l’approche de FDI

La figure 4.26 présente les résultats de l’estimation du position avant et après l’intégration de l’approche de FDI proposée. La performance de l’algorithme FDI est mise en évidence par

une ellipse bleue par rapport à la référence (courbe verte).

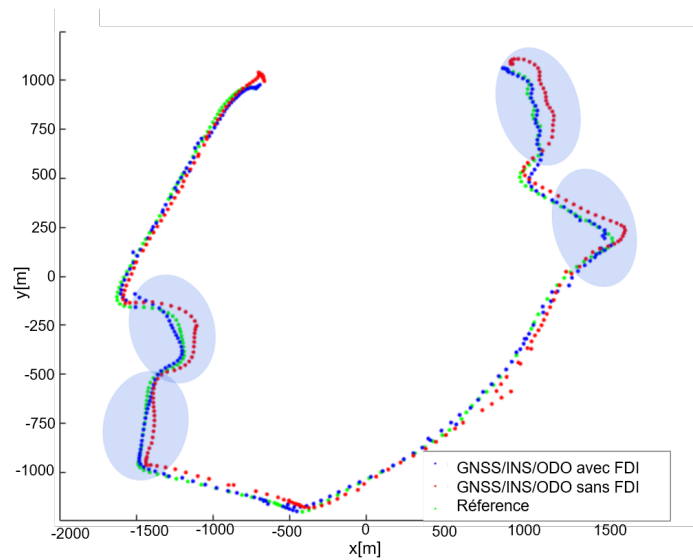


FIGURE 4.17 – Trajectoire avec et sans l'intégration de l'approche de FDI

Cependant, il est nécessaire d'analyser de manière approfondie la variation des paramètres liés à l'état du signal GNSS à la réception, tels que le résidu de chaque satellite disponible pendant la période de réception. Le résidu individuel α -RD de chaque satellite est illustré à la figure 4.18. Par exemple, les résidus des satellites 8, 10 et 26 présentent la plupart du temps une variation plus importante que les autres, généralement en raison d'un satellite ou plus de faible élévation, qui augmentent la probabilité des mesures erronées.




FIGURE 4.18 – Les résidus α -RD Partiels de chaque satellites pour la trajectoire entière

La présence de nombreux défauts peut être dû à divers facteurs tels que les satellites, le

récepteur, ou de la propagation des signaux. Par exemple, la dégradation d'un signal GNSS peut venir de plusieurs sources, comme des trajets multiples causés par les NLOS, la réflexion du signal mais aussi la faible élévation des satellites. La figure 4.19 montre que durant toute la trajectoire, les satellites 7 (bleu foncé), 8 (marron), et 10 (jaune) ont une basse élévation qui correspond à une source des défauts observés.




FIGURE 4.19 – Les élévations des satellites durant toute la trajectoire

Comparaison avec une approche de FDI basée sur un paramètre α fixe

Pour montrer l'efficacité et généralisation de l'approche proposée, il est important d'analyser et de comparer l'approche proposée basée sur la variable α à un algorithme avec une valeur fixe d' α . La figure 4.20 montre la comparaison entre l'erreur quadratique moyenne (EQM) de l'approche proposée basée sur la variable α estimée par le modèle RNP et d'une approche de FDI basée sur la divergence de Kullback Liebler (KLD) qui correspond à une valeur du paramètre α tend vers 1, pour une évaluation de la position finale. Les résultats montrent que l'algorithme proposé permet d'obtenir une erreur moyenne de la position estimée d'environ 5,23 mètres, alors que l'erreur moyenne de KLD pour l'estimation de la position est d'environ 7,88 mètres, avec des valeurs des pics d'erreurs qui pouvant atteindre jusqu'à 62 mètres d'erreur, ce qui témoigne de la performance de l'approche proposée à pouvoir réduire des erreurs de position.

4.5.6 Résultats d'une décision adaptée au contexte

Afin de prendre une décision appropriée concernant les mesures erronées, l'impact de la probabilité d'absence de défauts P_0 sur la partie de seuillage est prépondérant. Dans cette section, l'estimation de cette probabilité par un RNP est étudiée. Les entrées et le processus d'apprentissage du RNP proposés sont identiques à celui utilisé pour la sélection du paramètre α . Par contre, la labellisation de notre sortie (P_0) est complexe à réaliser pour chaque instant




FIGURE 4.20 – Résultats de la comparaison de l’approche proposé avec la divergence de Kullback Liebler

k dans notre application, sachant que les conditions environnementales changent. En effet, il est difficilement envisageable de pouvoir procurer un jeu de données d’apprentissage, dans lequel nous pourrions garantir à chaque instant que la probabilité de ne pas faire face à un défaut procurée a une valeur précise. En l’absence de toute possibilité de disposer d’une valeur précise, l’algorithme de FDI de référence est utilisé. Si celui-ci ne détecte pas de défaut la valeur du P_0 est fixée à une valeur haute (par exemple 0.8). Ensuite, pour chaque détection nouvelle le P_0 est négativement impacté (plafonné à 0.2).

Résultats de l’estimation de P_0 par apprentissage

Pour l’estimation de la probabilité de ne pas faire face à un défaut P_0 , l’architecture proposée est un réseau de neurones de convolution (CNN) à une dimension. Cette topolgy de RNP est illustrée dans la figure 4.21. Elle comprend 9 couches, dont une couche d’entrée, 2 couches de convolution, une couche de pooling max, une couche de flatten, 3 couches denses entièrement connectées et une couche de sortie pour l’estimation de P_0 . La couche d’entrée est composée d’une taille d’entrée de 114×4112 représentant des informations sur l’état du signal GNSS à chaque instant avec diverses variables telles que l’élévation des satellites, le DOP, le CMC, etc. Les couches suivantes représentent le bloc principal de construction d’un CNN : les "2 couches de convolution". Inspirée biologiquement par le traitement du cortex visuel des mammifères, chaque couche CNN est composée de 128 noyaux ou filtres avec une taille de fenêtre de 6. Particulièrement différente des topologies des réseaux neuronaux classiques, qui sont des couches entièrement connectées les unes aux autres, l’architecture CNN est basée sur l’opération dite de convolution, chaque neurone de la carte de caractéristiques reçoit des connexions uniquement d’un sous-ensemble de neurones de la couche précédente,

qui permettra d'abord d'extraire une corrélation locale des données d'entrée, et ensuite d'extraire les caractéristiques inhérentes de la couche CNN précédente. Au cours de ce processus, une nouvelle carte de caractéristiques est générée à chaque instant par la convolution entre les cartes de caractéristiques d'entrée et les noyaux puis une fonction est appliquée à ces opérations de convolution. Ainsi, la carte de caractéristiques de sortie de chaque couche est calculée comme suit : [175] :

$$y_j^i = f\left(\sum_{l \in M_j} y_j^{i-1} * k_j^i + b_j^i\right) \quad (4.7)$$

Où y_j^i représente la carte de caractéristiques produite par le j ème noyau convolutif à la i ème couche ; M_j représente toutes les cartes de caractéristiques à la $i-1$ ème couche ; k_j^i représente un noyau convolutif à la i ème couche ; b_j^i représente le biais correspondant aux caractéristiques y_j^i à la i ème couche ; $f()$ représente la fonction d'opération ; et $*$ représente l'opération de convolution.

Ensuite, pour réduire la dimension des caractéristiques, une couche de mise en commun maximale est mise en œuvre pour extraire les valeurs les plus élevées (252 caractéristiques les plus actives) de la dernière couche de convolution ; les caractéristiques extraites et apprises sont fusionnées en un vecteur unique composé de 252 fois 128 nombres, suivi de 3 couches cachées entièrement connectées composées de 128 nœuds chacune. La dernière couche est connectée à la couche de sortie qui contient 4112 nœuds avec *ReLU* comme fonction d'activation car la topologie développée est destinée à l'approche de régression [73]. Pour l'optimisation des réseaux neuronaux, un algorithme de rétropropagation est utilisé, en calculant la SGD qui met à jour les poids des neurones en utilisant des connexions de rétroaction pour délivrer l'erreur.

Les résultats concernant la performance du P_0 proposée en utilisant le RNP comparé à l'algorithme MLE pour les trajectoires de validation T1 et T2, sont présentés dans la figure 4.22. Pour rappel, ces deux trajectoires n'ont pas été utilisées pour la phase d'apprentissage. Les figures 4.22a et 4.22c montrent que les valeurs initiales de P_0 fournies par l'algorithme MLE sont différentes de celles attendues. Pour cet algorithme, la valeur initiale est fixée de manière heuristique, généralement autour de 0,5 en absence de connaissance préalable. En revanche, le P_0 estimé par RNP (figures 4.22b et 4.22d) est, dès le départ, adapté au contexte en considérant le nombre de satellites présents, leurs élévations, leur disposition géométrique et toutes les entrées RNP citées précédemment. De plus, le P_0 basé sur le RNP montre des variations dynamiques cohérentes par rapport à l'algorithme de fenêtrage qui suit une tendance de filtrage avec une faible variation (en fonction de la fenêtre choisie comme le montrent les figures 4.22a et 4.22c). Dans ces cas, P_0 utilisant MLE est souvent une faible probabilité de situation non défectueuse ce qui conduit à un seuil très conservateur. Le modèle du RNP sélectionné montre une amélioration significative par rapport à MLE et se rapproche

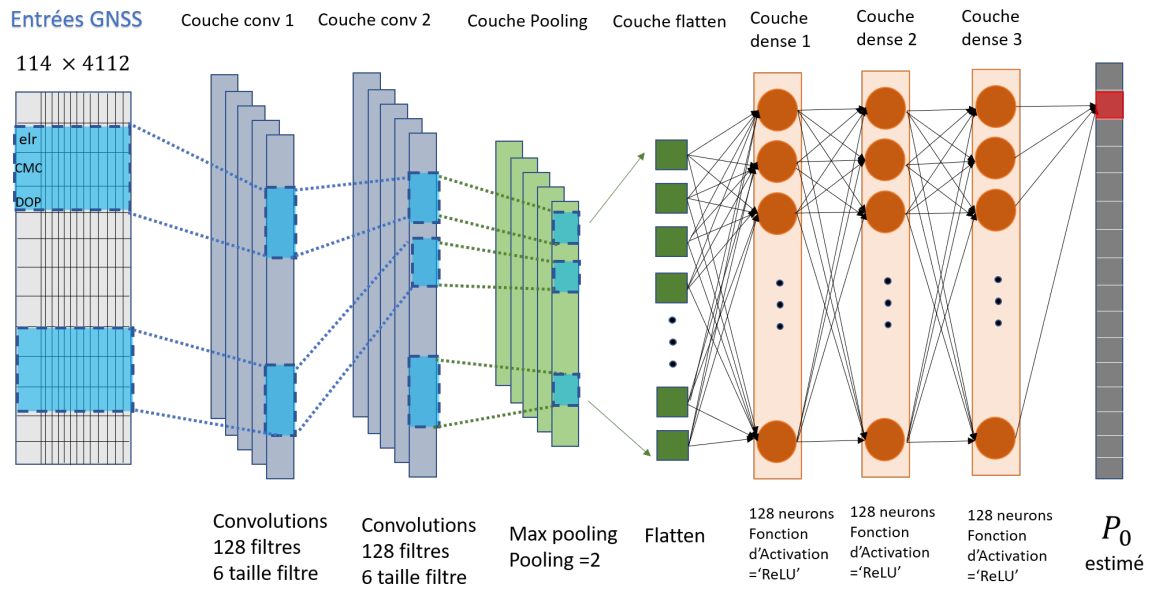

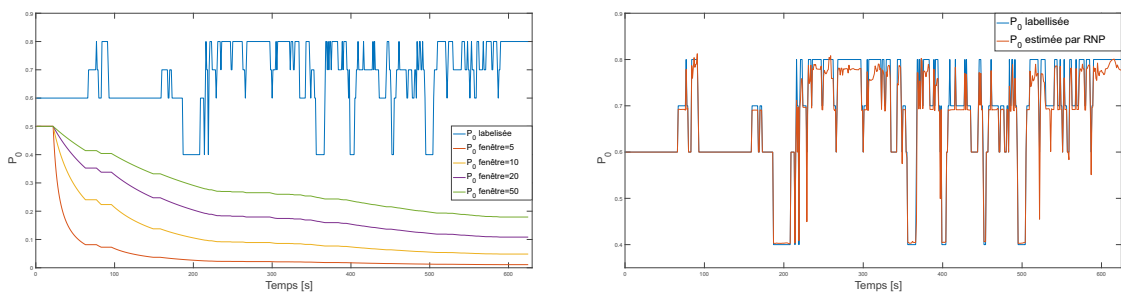


FIGURE 4.21 – Topologie du réseau de neurones de convolution proposée

du P_0 labellisé avec une erreur moyenne de 0,02%.



(a) L'estimation de P_0 par MLE comparée au (b) Résultats des performances de RNP pour P_0 labellisée par RNP pour la trajectoire T1 l'estimation de P_0 pour la trajectoire T1



(c) L'estimation de P_0 par MLE comparée au (d) Résultats des performances de RNP pour P_0 labellisée par RNP pour la trajectoire T2 l'estimation de P_0 pour la trajectoire T2

FIGURE 4.22 – Testing trajectories P_0 estimation performance

Résultats au niveau de l'estimation de position

Pour valider la solution proposée pour la prise de décision dans l'approche de FDI, l'analyse du comportement du résidu α -RD est une étape importante. La figure 4.23 montre le résidu α -RD est calculé avant et après l'intégration de la couche FDI. On constate qu'après l'intégration la valeur du résidu diminue, ce qui indique la présence de défauts.




FIGURE 4.23 – Résidus avec et sans l'intégration de l'approche de FDI

Afin de préciser quel(s) satellite(s) apporte(ent) des mesures erronées, la figure 4.24 représente les résidus α -RD pour chaque satellite visible. A titre d'exemple, les erreurs simultanées de l'instant 334 à 356 (zone rose 1), sont causées par les satellites 7 (bleu foncé), 8 (brun) et 27 (rouge). Concernant la période de 414 à 432 (zone rose 2), les satellites 8 (brun) et 27 (rouge) peuvent être la cause principale des erreurs dans cette zone.




FIGURE 4.24 – Les résidus α -RD Partiels de chaque satellites pour la trajectoire entière

La figure 4.25 montre que durant toute la trajectoire, les satellites 7 (bleu foncé) et 8 (marron) ont une basse élévation qui correspond à une source des défauts constatés.




FIGURE 4.25 – Les élévations des satellites durant toute la trajectoire

Les résultats dans 4.26 présentent l'estimation du position avant et après l'intégration de l'algorithme FDI. La performance de l'algorithme FDI est mise en évidence par une ellipse bleue par rapport à la référence (courbe verte).




FIGURE 4.26 – Trajectoire avec et sans l'intégration de l'approche de FDI

Comparaison de l'impact de l'estimation de P_0 sur la prise de décision

Dans cette section, nous menons une analyse approfondie de la performance de la partie de prise de décision dans la couche de FDI, et de son impact au niveau de la position, en utilisant l'estimation de P_0 basée sur le RNP proposé par rapport à un algorithme basé sur MLE avec fenêtre temporelle de taille 20 pour la trajectoire T2. Les résultats expérimentaux sont présentés en deux parties :

4.5. DÉVELOPPEMENT ET RÉSULTATS DU CONCEPT D'ADAPTATIVITÉ PAR APPRENTISSAGE

1. Nous analysons tout d'abord la différence entre les décisions de l'approche de FDI proposée dont l'estimation P_0 est basée sur un RNP et l'approche de FDI dont l'estimation est basée sur un MLE.
2. Nous comparons les performances des deux méthodes étudiées au niveau de la position, afin de montrer l'efficacité de la méthode proposée à retirer les défauts soudains dans des zones critiques de localisation.

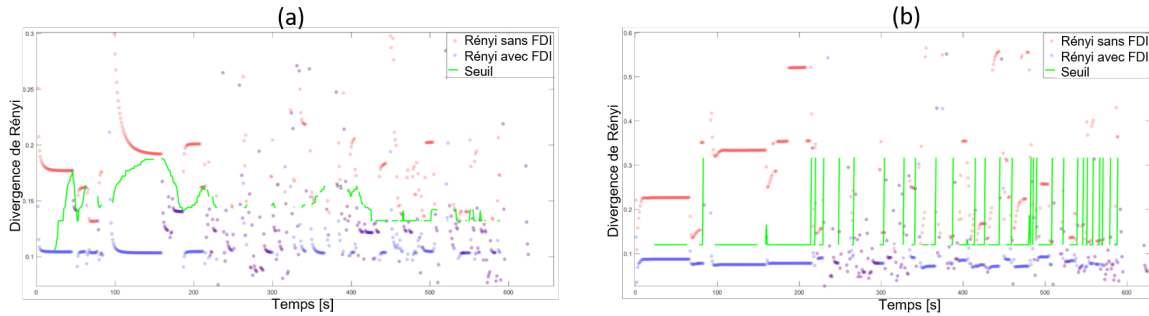



FIGURE 4.27 – (a) Résidus avec et sans défauts basés sur un seuil utilisant MLE, (b) Résidus avec et sans défauts basés sur un seuil utilisant un RNP

La figure 4.27 montre une comparaison du seuil calculé sur la base des deux approches. Dans la figure 4.27a le calcul du seuil est basé sur l'algorithme de MLE, tandis que sur la figure 4.27b le seuil est calculé en se basant sur le RNP. La méthode proposée permet d'obtenir des améliorations significatives en termes d'isolation de défaut(s) avec des variations dynamiques de cohérence avec les changements de contexte de navigation.



(a) Les résultats d'isolation des satellites isolées basées sur une décision prise par MLE (b) Les résultats d'isolation des satellites isolées basées sur une décision prise par RNP

FIGURE 4.28 – L'impact de P_0 sur la prise de décision

Analyse de l'erreur de position

Afin d'évaluer la performance de la fonction de localisation, une comparaison des décisions résultant des deux approches est effectuée. La figure 4.28a montre les satellites isolés




FIGURE 4.29 – La différence au niveau de la prise de décision en utilisant P_0 estimé avec MLE et RNP

en se basant sur l'estimation de P_0 par MLE. La figure 4.28b montre les satellites isolés en utilisant un P_0 estimé par le RNP proposé. Les deux figures montrent une majorité de décisions identiques, ainsi que quelques différences.

La Figure 4.29 montre uniquement les décisions différentes en utilisant les deux approches pour l'estimation de P_0 . En rouge, on constate l'isolation des défauts effectuée par une méthode de FDI dont la prise de décision est basée sur MLE. En noir, on trouve l'isolation, où la prise de décision dans la couche de diagnostic est faite par RNP. Par exemple, de l'instant 451 à 470 (zone rose), la décision utilisant l'algorithme MLE était d'isoler les satellites 7 et 21 alors que dans la décision utilisant l'algorithme RNP, les satellites 10 et 26 présentent des mesures erronées. Comme certaines décisions ne sont pas les mêmes, on peut s'attendre à une dégradation des performances de la fonction de localisation pour l'une des deux méthodes. La figure 4.30 montre une comparaison des performances relatives des deux




FIGURE 4.30 – L'évaluation des performances de l'approche proposée au niveau de la position

approches. En calculant la différence entre les erreurs de position fournies par *l'indicateur de performance relative (Relative Performance Indicator RPI)* détaillé dans l'équation suivante, nous constatons l'impact des décisions de l'approche RNP proposée et de l'algorithme MLE sur la position.

$$RPI = RMSE(X_{MLE}, X_{Reference}) - RMSE(X_{RNP}, X_{Reference}) \quad (4.8)$$

Avec *RMSE (Root Mean Square Error)* : L'écart quadratique moyen d'erreur.

En se basant sur cette équation, la partie positive de la courbe, indique que l'approche de FDI proposée basé sur le RNP prend la (les) meilleure(s) décision(s), puisqu'elle est la plus proche de la vérité terrain. Inversement, la partie négative de la courbe, montre que l'approche de diagnostic basée sur MLE prend les meilleures décisions des deux méthodes étudiées. Si le RPI est égal à zéro, cela signifie que les deux approches ont pris des décisions identiques et fournissent la même erreur de position. Nous pouvons souligner, que l'approche proposée prend des meilleures décisions et par conséquent estime une position plus précise que l'algorithme MLE, ce qui résulte en une diminution de l'erreur de position (près de 80 mètres pour le meilleur cas). Cependant, pour certains cas, l'algorithme MLE réalise un meilleur positionnement et par conséquent de meilleures décisions. Ces situations peuvent être expliquées par quatre raisons complémentaires. La première est que la quantité de données utilisées pour entraîner le RNP n'était pas suffisante, et lors de la phase de test, le RNP a été confronté à des situations non apprises. La deuxième explication possible est l'insuffisance des entrées. La troisième explication est l'absence d'une meilleure possibilité de labelliser P_0 . Et la dernière explication, qui est la plus probable, est la différence entre les types fautes ciblées. En effet, la solution proposée basée sur un RNP est conçue pour des défauts soudains alors que MLE est plus performant avec des erreurs naissantes.

Afin d'évaluer les performances des deux méthodes, nous calculons l'erreur moyenne et l'erreur maximale détectées par chaque approche. Les résultats sont présentés dans le tableau 4.5.

TABLE 4.5 – Evaluation des performances des deux approches par des métriques d'erreur

Erreur	Retiré par RNP	Retiré par MLE
Métrique [m]		
Erreur moyenne	8.247	3.353
Erreur maximale	80.141	15.347

La Figure 4.31 présente une vue 2D de la trajectoire avec les deux algorithmes mis en




FIGURE 4.31 – Performance des deux différentes méthodes d’estimation de la position ; position estimée basée sur une décision utilisant le RNP (magenta) et position estimée basée sur une décision utilisant MLE (violet) dans différents contextes de navigation.

œuvre par rapport à la référence. La trajectoire obtenue avec l’approche de FDI basée sur le RNP est tracée en couleur magenta, et la trajectoire bleue est la résultante d’une approche de FDI avec une prise de décision basée sur l’algorithme MLE. De plus, nous avons zoomé sur les zones critiques (zone jaune) à la sortie d’un tunnel, le passage à côté des arbres pour montrer clairement l’effet de chaque méthode sur la position finale.

4.6 Conclusion

Dans ce chapitre, nous avons proposé une mise en œuvre expérimentale des approches proposées dans le chapitre 3. Tout d’abord, le cadre expérimentale global a été présenté ; le véhicule de test, les équipements techniques utilisé et l’ensemble des trajectoires réelles utilisées pour la collection des données.

Pour tester et valider le concept d’adaptativité, nous avons présenté le processus d’apprentissage pour deux parties de la couche de diagnostic :

- La sélection du paramètre α .
- La prise de décision sous-incertitude.

Dans la première partie de ce chapitre, nous avons commencé par une illustration générale du processus de paramétrisation du résidu et la sélection du paramètre α . Dans cette section l’ensemble du processus d’adaptativité a été détaillé par étape. Tout d’abord, les outils de collection de données ont été présenté : Les observations GNSS réelles avec le véhicule expérimentale et par l’utilisation du simulateur/émulateur Stella NGC.

Par la suite, nous avons présenté les critères de choix concernant les entrées du réseau de

neurones (la sélection des caractéristiques des signaux GNSS pertinentes et leur partitionnement selon le contexte de navigation), l'architecture du réseau de neurones et la technique de labellisation de la sortie (le paramètre α).

Pour montrer les performances de l'approche proposée, nous avons comparé les résultats de la méthode de diagnostic adaptive basée sur un résidu paramétré, dont le paramètre α varie selon le contexte de navigation, avec une approche de FDI où la valeur du paramètre α est fixe (KLD). Les expérimentations réelles ont permis de montrer le bon fonctionnement de la stratégie développée. Sur toute la trajectoire de test, nous retiendrons que la meilleure performance est à accrédi-ter à la méthode de FDI basée sur α -RD paramétré par rapport à la méthode de FDI basée sur KLD.

Dans la deuxième partie, nous avons discuté la probabilité d'absence de défauts P_0 et son impact sur le calcul de seuil. Ainsi, nous avons implémenté un réseau de neurones profond à la place de l'algorithme MLE pour retirer les défauts soudaines du GNSS. Dans ce contexte, une comparaison des résultats de performances de l'approche de FDI basée sur des décisions prises par RPN et l'approche basée sur des décisions prises par MLE a été réalisée. Les résultats de localisation sur la trajectoire de test qui en découlent sont très satisfaisants.

Enfin, le concept d'adaptativité a été testé et validé compte tenu de sa capacité pour retirer les erreurs GNSS et réduire l'erreur de position du véhicule.

Chapitre 5

Conclusion et perspectives

5.1 Conclusion

Depuis plusieurs décennies, l'évolution dans le domaine de transport a mis à profit la localisation par les systèmes de positionnement satellitaire GNSS. Ces systèmes ont gagné en intérêt et en popularité. En effet, en termes de développement et d'exploitation des systèmes GNSS, l'innovation a toujours été au cœur des préoccupations, en considérant qu'ils sont capable de répondre à de nombreuses exigences opérationnelles, principalement l'intégrité. Ces technologies ont permis d'envisager la réalisation d'applications critiques ou à haut niveau de sûreté, telles que les véhicules autonomes. Les systèmes GNSS présentent divers les avantages : leur couverture mondiale, leur continuité et leur prix en ont fait les plus répandus pour la localisation extérieur.

Cependant, ces systèmes ont certains inconvénients tels que la perturbation des signaux provoquée par le changement du contexte de navigation. Dans les environnements complexes, plusieurs phénomènes peuvent perturber la réception d'un signal GNSS, et par conséquent dégrader la performance du système de localisation. Par exemple, les réflexions des signaux entraînent une augmentation de l'imprécision de la position ou encore les masquage de signaux peut entraîner une indisponibilité de la position. Pour atténuer ces phénomènes, plusieurs solutions existent dans la littérature. Pour l'augmentation de la disponibilité du système de localisation, l'ajout de capteurs supplémentaires est souvent utilisé pour compenser l'absence du signal GNSS. Pour assurer la sûreté, l'implémentation des algorithmes pour détecter les erreurs au niveau de la position est généralement proposée. Néanmoins, l'effet du changement du contexte de navigation est peu abordé dans la plupart des travaux et reste à présent un véritable défi pour la communauté scientifique. Dans ce contexte, les travaux de cette thèse ont été focalisés sur les différentes niveaux d'amélioration des exigences de la localisation en se basant sur une approche innovante de localisation qui s'adapte à l'environnement par apprentissage.

Pour atteindre ces objectifs, le travail réalisé a été structuré autour de 4 chapitres. Le chapitre 1 présente le contexte générale de la thèse : les enjeux principales dans le développement d'un véhicule autonome et particulièrement la brique de localisation. Ensuite, les exigences opérationnelles (KPIs) sont détaillées. Enfin, l'originalité et les contributions proposées dans ce travail sont présentées.

Le chapitre 2 aborde un état de l'art sur les différentes couches d'amélioration des performances du système de localisation. En premier lieu, les principes fondamentaux des capteurs utilisées pour la localisation, particulièrement les technologies de positionnement par satellites pour les applications transports ont été détaillées. Nous introduisons les concepts de base des systèmes GNSS : le principe de fonctionnement, les constellations, les avantages et les perturbations connues de la propagation du signal dues principalement à l'environnement du véhicule. Ensuite, les capteurs proprioceptifs et extéroceptifs tels que IMU/INS, LiDAR et odomètre ont été présentés. Par la suite, la complémentarité des technologies a été mise en évidence afin de souligner l'intérêt de la fusion de données multi-capteurs et son rôle pour améliorer la précision de la position. Puis, nous avons présenté les différentes architectures d'intégration des mesures brutes GNSS/INS. En deuxième lieu, la nécessité d'une couche de diagnostic pour assurer l'intégrité du système est soulignée. Dans cette partie, les méthodes de diagnostic classiques et par apprentissage ont été introduites, ainsi que plusieurs définitions, acronymes et termes généralement utilisées dans le domaine du diagnostic. Nous avons également évoqué le besoin d'un estimateur robuste en ce qui concerne la non-linéarité du système, nous attardant particulièrement sur le filtrage bayésien (le filtre informationnel) pour estimer la position du véhicule. Par la suite, les méthodes d'évaluation des résidus et prise de décision sont évoquées. Enfin, nous avons présenté l'UIO pour l'isolation des mesures erronées GNSS.

Dans le chapitre 3, nous avons présenté l'approche proposée "le concept d'adaptativité par apprentissage". Nous avons détaillé cette approche multi-objectives sous plusieurs niveaux. D'abord pour assurer la précision de la position, nous avons présenté l'intégration à couplage serré en utilisant le filtrage informationnel des technologies GNSS/INS/odomètre. Ensuite, pour augmenter l'intégrité du système, nous avons repris la problématique de l'adaptativité d'une couche de diagnostic à l'environnement. Dans ce contexte, nous avons présenté brièvement des travaux qui s'intéressent à améliorer les performances des systèmes GNSS par la caractérisation environnementale. Cependant, ces travaux sont souvent dédiées à un environnement statique comme 'l'environnement urbain'. Ils ne considèrent pas le changement brusque d'un environnement à un autre qui peut représenter une source principale des défauts soudaines GNSS. Afin de répondre au contraintes exposées, nous avons évoqué la nouveauté de notre approche, qui propose une couche de diagnostic capable de satisfaire les exigences opérationnelles (KPIs) à chaque instant et dans différents contextes environnementaux. Dans l'optique de concevoir une méthode de FDI adaptative à l'environnement, nous avons proposé

l'utilisation des méthodes d'apprentissage automatique et profond dans la partie de détection de défauts sur deux niveaux. Dans un premier temps, la conception des résidus paramétrés basés sur la divergence informationnelle α -Rényi. Nous avons ainsi proposé la sélection du paramètre α selon le contexte environnemental par un réseau de neurones profond. Dans second temps, les résidus sont évalués par une méthode de seuillage en vue d'isoler les mesures erronées de la procédure de fusion. Cette approche est basée sur un critère d'optimisation informationnel et renforcé par un réseau de neurones de convolution.

Afin de tester et valider les performances de l'approche proposée, nous avons présenté au début du chapitre 4 les moyens expérimentaux utilisés, leurs installations et leurs configurations, pour effectuer les essais et les tests des algorithmes développés. Ensuite, nous avons présenté les algorithmes d'apprentissage développés, leurs entrées, leurs topologies et la méthode de labellisation de leurs sortie.

Finalement, l'importance d'une couche de diagnostic adaptative à l'environnement de navigation par rapport à celles existantes dans la littérature apparaît à travers une comparaison des résultats des performances de l'approche proposée, dont le paramètre α appris par RNP varie selon le contexte de navigation, à celles d'une approche de FDI basée sur un α fixe (*KLD*). Les résultats ont montré que l'utilisation des méthodes l'apprentissage pour la sélection du paramètre α et la méthode de seuillage a rendu plus performante l'étape de diagnostic des mesures GNSS erronées.

5.2 Perspectives

Les résultats encourageants obtenus confirment nos motivations pour le choix des outils méthodologiques proposés, en particulier le diagnostic adaptatif par apprentissage. Cependant, certaines limitations peuvent être pointées et peuvent constituer des pistes pour des travaux futurs. Nous énumérons ci-dessous plusieurs points, à traiter dans la perspective de ce travail :

- **Amélioration du modèle d'apprentissage** L'utilisation de l'apprentissage profond dans le domaine du diagnostic pour la localisation est de plus en plus fréquente. Nous pensons que notre outil pourrait être amélioré en le rendant dynamique, c'est à dire d'utiliser une méthode d'apprentissage en ligne. Concernant le modèle d'entraînement, il serait mieux d'augmenter le nombre de données (plus de scénarios diversifiés) pour améliorer ses performances et réduire son erreur d'estimation. Avec la disponibilité des ressources en terme de puissance de calcul, les résultats du modèle d'apprentissage pourraient être donnés en temps réel, pourraient devenir plus accessible et seraient un nouveau pas envers une localisation sûre et précise.
- **Intégration des informations d'une cartographie 3D** Une perspective serait de

pouvoir intégrer des données supplémentaires dans les entrées du réseau de neurones comme les données d'une cartographie 3D qui peut fournir des informations pertinentes sur l'environnement d'un véhicule comme la taille des bâtiments, les Forêts pour aboutir à un outil plus complet qui assisterait les utilisateurs dans leur décision.

- **Estimation des matrices de covariances du filtre d'intégration par apprentissage** Le filtre informationnel, lorsqu'il est utilisé pour les applications GNSS comme estimateur d'état, fournit des solutions optimales si les statistiques de bruit pour la mesure et le système sont complètement connues. En pratique, le bruit varie dans le temps, ce qui entraîne une dégradation des performances. Il est nécessaire d'adapter l'estimation des matrices de covariance de prédiction et correction au contexte environnemental et aux KPIs. Dans un travail futur, on souhaite utiliser un réseau de neurones multicouches pour identifier les matrices de covariance du bruit de mesure et du modèle d'évolution à chaque instant en vue d'avoir une cohérence entre l'estimation du filtre et le contexte de navigation.
- **Variété des défauts capteurs** L'approche proposée a été appliquée seulement sur des défauts GNSS. Dans un travail futur, nous souhaitons nous orienter vers la détection des défauts d'autres capteurs IMU, odomètre.
- **Détermination des bornes de protection** : Il serait intéressant de déterminer les bornes de protection horizontale HPL et verticale VPL (Horizontal and Vertical Protection Level) correspondant à la divergence α -Rényi afin d'étudier la disponibilité du système.
- **Application sur un système multi-véhicules** Dans cette thèse, l'approche proposée a été appliquée pour un seul véhicule. Dans les travaux futurs, nous prévoyons de montrer l'intérêt de la méthode proposée pour les système autonome multi-véhicules.

Bibliographie

- [1] T. ABBAS, M. ARIF et W. AHMED. « Measurement and correction of systematic odometry errors caused by kinematics imperfections in mobile robots ». In : *2006 SICE-ICASE International Joint Conference*. IEEE. 2006, p. 2073-2078.
- [2] L. ACHAJI, M. DAHER, M. E. B. EL NAJJAR et F. CHARPILLET. « Multi-Sensor Data Fusion for Smart Home Reliable Pedestrian Localization ». In : *2021 IEEE 3rd International Multidisciplinary Conference on Engineering Technology (IMCET)*. IEEE. 2021, p. 144-149.
- [3] C. C. AGGARWAL. « Neural networks and deep learning ». In : *Springer* 10 (2018), p. 978-3.
- [4] P. AGGARWAL. *MEMS-based integrated navigation*. Artech House, 2010.
- [5] J. AL HAGE, M. E. EL NAJJAR et D. POMORSKI. « Multi-sensor fusion approach with fault detection and exclusion based on the Kullback–Leibler Divergence : Application on collaborative multi-robot system ». In : *Information Fusion* 37 (2017), p. 61-76.
- [6] S. AMMANA. « An Analysis of GPS Code Minus Carrier Measurements for GBAS Applications. » In : *IUP Journal of Electrical & Electronics Engineering* 11.1 (2018).
- [7] E. ARNOLD, O. Y. AL-JARRAH, M. DIANATI, S. FALLAH, D. OXTOBY et A. MOUZAKITIS. « A survey on 3d object detection methods for autonomous driving applications ». In : *IEEE Transactions on Intelligent Transportation Systems* 20.10 (2019), p. 3782-3795.
- [8] S. A. BAGLOEE, M. TAVANA, M. ASADI et T. OLIVER. « Autonomous vehicles : challenges, opportunities, and future implications for transportation policies ». In : *Journal of modern transportation* 24.4 (2016), p. 284-303.

- [9] X. BAI, W. WEN et L.-T. HSU. « Using Sky-pointing fish-eye camera and LiDAR to aid GNSS single-point positioning in urban canyons ». In : *IET Intelligent Transport Systems* 14.8 (2020), p. 908-914.
- [10] M. BASSEVILLE, I. V. NIKIFOROV et al. *Detection of abrupt changes : theory and application*. T. 104. prentice Hall Englewood Cliffs, 1993.
- [11] A. BHATTACHARYA, D. PATI, Y. YANG et al. « Bayesian fractional posteriors ». In : *The Annals of Statistics* 47.1 (2019), p. 39-66.
- [12] A. BHATTACHARYA, P. KAR et M. PAL. « On low distortion embeddings of statistical distance measures into low dimensional spaces ». In : *International Conference on Database and Expert Systems Applications*. Springer. 2009, p. 164-172.
- [13] K. BIMBRAW. « Autonomous cars : Past, present and future a review of the developments in the last century, the present scenario and the expected future of autonomous vehicle technology ». In : *2015 12th international conference on informatics in control, automation and robotics (ICINCO)*. T. 1. IEEE. 2015, p. 191-198.
- [14] N. BLANCO-DELGADO et M. U. de HAAG. « Multipath analysis using code-minus-carrier for dynamic testing of GNSS receivers ». In : *2011 International Conference on Localization and GNSS (ICL-GNSS)*. IEEE. 2011, p. 25-30.
- [15] S. G. BOBKOV, G. CHISTYAKOV, F. GÖTZE et al. « Rényi divergence and the central limit theorem ». In : *The Annals of Probability* 47.1 (2019), p. 270-323.
- [16] R. N. BOLTON, J. R. MCCOLL-KENNEDY, L. CHEUNG, A. GALLAN, C. ORSINGHER, L. WITTELL et al. « Customer experience challenges : bringing together digital, physical and social realms ». In : *Journal of Service Management* 29.5 (2018), p. 776-808.
- [17] H. BOSTRÖM, S. F. ANDLER, M. BROHEDE, R. JOHANSSON, A. KARLSSON, J. VAN LAERE et al. *On the definition of information fusion as a field of research*. 2007.
- [18] A. BOTCHKAREV. « Performance metrics (error measures) in machine learning regression, forecasting and prognostics : Properties and typology ». In : *arXiv preprint arXiv :1809.03006* (2018).

-
- [19] L. M. BREGMAN. « The relaxation method of finding the common point of convex sets and its application to the solution of problems in convex programming ». In : *USSR computational mathematics and mathematical physics* 7.3 (1967), p. 200-217.
- [20] F. BRUNNER, H. HARTINGER et L. TROYER. « GPS signal diffraction modeling : the stochastic SIGMA- Δ model ». In : *Journal of Geodesy* 73.5 (1999), p. 259-267.
- [21] M. BUEHLER, K. IAGNEMMA et S. SINGH. *The DARPA urban challenge : autonomous vehicles in city traffic*. T. 56. springer, 2009.
- [22] S. CAMPBELL, N. O'MAHONY, L. KRPALCOVA, D. RIORDAN, J. WALSH, A. MURPHY et al. « Sensor technology in autonomous vehicles : A review ». In : *2018 29th Irish Signals and Systems Conference (ISSC)*. IEEE. 2018, p. 1-4.
- [23] A. CANEDO-RODRIGUEZ, V. ALVAREZ-SANTOS, C. V. REGUEIRO, R. IGLESIAS, S. BARRO et J. PRESEDO. « Particle filter robot localisation through robust fusion of laser, WiFi, compass, and a network of external cameras ». In : *Information Fusion* 27 (2016), p. 170-188.
- [24] L. CARLONE, J. DU, M. K. NG, B. BONA et M. INDRI. « An application of Kullback-Leibler divergence to active SLAM and exploration with particle filters ». In : *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE. 2010, p. 287-293.
- [25] G. CASELLA et R. L. BERGER. « Statistical Inference. Brooks ». In : *Cole Publishing, CADenux T, Masson MH, Hbert PA (2005) Nonparametric rank-based statistics and significance tests for fuzzy data. Fuzzy Sets Syst* 153 (1990), 128Dubois.
- [26] F. CASTANEDO. « A review of data fusion techniques ». In : *The scientific world journal* 2013 (2013).
- [27] V. CHANDOLA, A. BANERJEE et V. KUMAR. « Anomaly detection : A survey ». In : *ACM computing surveys (CSUR)* 41.3 (2009), p. 1-58.
- [28] J. CHEN et R. J. PATTON. *Robust model-based fault diagnosis for dynamic systems*. T. 3. Springer Science & Business Media, 2012.
- [29] K.-W. CHIANG, N. EL-SHEIMY et A. NOURELDIN. « A new weights updating method for neural networks based INS/GPS integration architectures ». In : *measurement science and technology* 15.10 (2004), p. 2053-2061.

- [30] K.-W. CHIANG et N. EL-SHEIMY. « INS/GPS integration using neural networks for land vehicle navigation applications ». In : *Proceedings of the 15th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GPS 2002)*. 2002, p. 535-544.
- [31] K.-W. CHIANG, G.-J. TSAI, Y.-H. LI, Y. LI et N. EL-SHEIMY. « Navigation engine design for automated driving using INS/GNSS/3D LiDAR-SLAM and integrity assessment ». In : *Remote Sensing* 12.10 (2020), p. 1564.
- [32] J. K. CHOI et Y. G. JI. « Investigating the importance of trust on adopting an autonomous vehicle ». In : *International Journal of Human-Computer Interaction* 31.10 (2015), p. 692-702.
- [33] E. CHOW et A. WILLSKY. « Analytical redundancy and the design of robust failure detection systems ». In : *IEEE Transactions on automatic control* 29.7 (1984), p. 603-614.
- [34] R. CLAWGES, K. VIERLING, L. VIERLING et E. ROWELL. « The use of airborne lidar to assess avian species diversity, density, and occurrence in a pine/aspen forest ». In : *Remote Sensing of Environment* 112.5 (2008), p. 2064-2073.
- [35] H. CUI, V. RADOSAVLJEVIC, F.-C. CHOU, T.-H. LIN, T. NGUYEN, T.-K. HUANG et al. « Multimodal trajectory predictions for autonomous driving using deep convolutional networks ». In : *2019 International Conference on Robotics and Automation (ICRA)*. IEEE. 2019, p. 2090-2096.
- [36] C. C. DANY NGUYEN-LUON. *Expérimentation et déploiement du véhicule en Île-de-France*. T. 100. IAU île-de-France, 2019.
- [37] J. DE KLEER et J. S. BROWN. « A qualitative physics based on confluences ». In : *Artificial intelligence* 24.1-3 (1984), p. 7-83.
- [38] G. DELMAIRE, J.-P. CASSAR et M. STAROSWIECKI. « Identification and parity space techniques for failure detection in SISO systems including modelling errors ». In : *Proceedings of 1994 33rd IEEE Conference on Decision and Control*. T. 3. IEEE. 1994, p. 2279-2285.
- [39] G. A. DEMETRIOU. « A Survey of Sensors for Localization of Unmanned Ground Vehicles (UGVs) ». In : *IC-AI*. Citeseer. 2006, p. 659-668.
- [40] L. DENG, J. LI, J.-T. HUANG, K. YAO, D. YU, F. SEIDE et al. « Recent advances in deep learning for speech research at Microsoft ». In : *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*. IEEE. 2013, p. 8604-8608.

-
- [41] P. J. DENNING. « Fault tolerant operating systems ». In : *ACM Computing Surveys (CSUR)* 8.4 (1976), p. 359-389.
- [42] E. D. DICKMANN et V. GRAEFE. « Dynamic monocular machine vision ». In : *Machine vision and applications* 1.4 (1988), p. 223-240.
- [43] D.-T. DINH, T. FUJINAMI et V.-N. HUYNH. « Estimating the optimal number of clusters in categorical data clustering by silhouette coefficient ». In : *International Symposium on Knowledge and Systems Sciences*. Springer. 2019, p. 1-17.
- [44] S. P. DRAKE. « Converting GPS coordinates [phi, lambda, h] to navigation coordinates (ENU) ». In : (2002).
- [45] H. DURRANT-WHYTE et T. C. HENDERSON. « Multisensor data fusion ». In : *Springer handbook of robotics* (2016), p. 867-896.
- [46] L. ERHAN, M. NDUBUAKU, M. DI MAURO, W. SONG, M. CHEN, G. FORTINO et al. « Smart anomaly detection in sensor systems : A multi-perspective review ». In : *Information Fusion* 67 (2021), p. 64-79.
- [47] P. J. ESCAMILLA-AMBROSIO et N. MORT. « Hybrid Kalman filter-fuzzy logic adaptive multisensor data fusion architectures ». In : *42nd IEEE International Conference on Decision and Control (IEEE Cat. No. 03CH37475)*. T. 5. IEEE. 2003, p. 5215-5220.
- [48] A.-C. ESCHER, C. MACABIAU, N. MARTIN, B. ROTURIER et V. VOGEL. « GNSS/IRS hybridization : fault detection and isolation of more than one range failure ». In : *Proceedings of the 15th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GPS 2002)*. 2002, p. 2619-2629.
- [49] G. FALCO, M. PINI et G. MARUCCO. « Loose and tight GNSS/INS integrations : Comparison of performance assessed in real urban scenarios ». In : *Sensors* 17.2 (2017), p. 255.
- [50] J. FAYYAD, M. A. JARADAT, D. GRUYER et H. NAJJARAN. « Deep learning sensor fusion for autonomous vehicle perception and localization : A review ». In : *Sensors* 20.15 (2020), p. 4220.
- [51] M. FORREST, T. SPRACKLEN et N. RYAN. « An inertial navigation data fusion system employing an artificial neural network as the data integrator ». In : *2000 : Navigating into the New Millennium* (2000), p. 153-158.

- [52] P. M. FRANK. « Analytical and qualitative model-based fault diagnosis—a survey and some new results ». In : *European Journal of control* 2.1 (1996), p. 6-28.
- [53] H. GAO et P. D. GROVES. « Environmental context detection for adaptive navigation using GNSS measurements from a smartphone ». In : *Navigation : Journal of the Institute of Navigation* 65.1 (2018), p. 99-116.
- [54] Y. GAO, S. LIU, M. M. ATIA et A. NOURELDIN. « INS/GPS/LiDAR integrated navigation system for urban and indoor environments using hybrid scan matching algorithm ». In : *Sensors* 15.9 (2015), p. 23286-23302.
- [55] D. GEBRE-EGZIABHER, M. PETOVELLO et G. LACHAPELLE. « What is the difference between 'loose', 'tight', 'ultra-tight' and 'deep' integration strategies for INS and GNSS ». In : *Inside GNSS* 1 (2007), p. 28-33.
- [56] J. GERTLER. « Analytical redundancy methods in fault detection and isolation—survey and synthesis ». In : *IFAC Proceedings Volumes* 24.6 (1991), p. 9-21.
- [57] J. GERTLER et D. SINGER. « A new structural framework for parity equation-based failure detection and isolation ». In : *Automatica* 26.2 (1990), p. 381-388.
- [58] X. GLOROT, A. BORDES et Y. BENGIO. « Deep sparse rectifier neural networks ». In : *Proceedings of the fourteenth international conference on artificial intelligence and statistics*. 2011, p. 315-323.
- [59] C. C. GOAD. « Precise positioning with the GPS ». In : *Applied Geodesy*. Springer, 1987, p. 17-30.
- [60] S. GODHA et M. CANNON. « GPS/MEMS INS integrated system for navigation in urban areas ». In : *Gps Solutions* 11.3 (2007), p. 193-203.
- [61] I. GOODFELLOW, Y. BENGIO et A. COURVILLE. *Deep learning*. MIT press, 2016.
- [62] P. GREENWAY et R. H. DEAVES. « Information filter for decentralized data fusion and sensor management ». In : *Signal Processing, Sensor Fusion, and Target Recognition III*. T. 2232. SPIE. 1994, p. 70-78.
- [63] M. S. GREWAL, L. R. WEILL et A. P. ANDREWS. *Global positioning systems, inertial navigation, and integration*. John Wiley & Sons, 2007.
- [64] S. GRIGORESCU, B. TRASNEA, T. COCIAS et G. MACESANU. « A survey of deep learning techniques for autonomous driving ». In : *Journal of Field Robotics* 37.3 (2020), p. 362-386.

-
- [65] S. GRIME et H. F. DURRANT-WHYTE. « Data fusion in decentralized sensor networks ». In : *Control engineering practice* 2.5 (1994), p. 849-863.
- [66] P. D. GROVES. « Principles of GNSS, inertial, and multisensor integrated navigation systems, [Book review] ». In : *IEEE Aerospace and Electronic Systems Magazine* 30.2 (2015), p. 26-27.
- [67] P. D. GROVES et Z. JIANG. « Height aiding, C/N0 weighting and consistency checking for GNSS NLOS and multipath mitigation in urban areas ». In : *The Journal of Navigation* 66.5 (2013), p. 653-669.
- [68] P. D. GROVES, L. WANG, M. ADJRAD et C. ELLUL. « GNSS shadow matching : The challenges ahead ». In : *Proceedings of the 28th International Technical Meeting of The Satellite Division of the Institute of Navigation (ION GNSS+ 2015)*. 2015, p. 2421-2443.
- [69] D. L. HALL et J. LLINAS. « An introduction to multisensor data fusion ». In : *Proceedings of the IEEE* 85.1 (1997), p. 6-23.
- [70] D. L. HALL et S. A. MCMULLEN. *Mathematical techniques in multisensor data fusion*. Artech House, 2004.
- [71] H. HAMADI, B. LUSSIER, I. FANTONI et C. FRANCIS. « Data fusion fault tolerant strategy for a quadrotor UAV under sensors and software faults ». In : *ISA Transactions* (2022).
- [72] X. HAN, S. A. KAZIM, N. A. TMAZIRTE, J. MARAIS et D. LU. « GNSS/IMU Tightly Coupled Scheme with Weighting and FDE for Rail Applications ». In : *ION ITM 2020-International Technical Meeting of Institute of Navigation*. 2020, 14p.
- [73] K. HARA, D. SAITO et H. SHOUNO. « Analysis of function of rectified linear unit used in deep learning ». In : *2015 international joint conference on neural networks (IJCNN)*. IEEE. 2015, p. 1-8.
- [74] J. HARMOUCHE, C. DELPHA et D. DIALLO. « Incipient fault detection and diagnosis based on Kullback–Leibler divergence using principal component analysis : Part I ». In : *Signal processing* 94 (2014), p. 278-287.
- [75] D. M. HAWKINS. *Identification of outliers*. T. 11. Springer, 1980.
- [76] A. M. HERRERA, H. F. SUHANDRI, E. REALINI, M. REGUZZONI et M. C. de LACY. « goGPS : open-source MATLAB software ». In : *GPS solutions* 20.3 (2016), p. 595-603.

- [77] A. HILL, E. LUCET et R. LENAIN. « A New Neural Network Feature Importance Method : Application to Mobile Robots Controllers Gain Tuning. » In : *ICINCO*. 2020, p. 188-194.
- [78] G. HINTON, L. DENG, D. YU, G. E. DAHL, A.-r. MOHAMED, N. JAITLY et al. « Deep neural networks for acoustic modeling in speech recognition : The shared views of four research groups ». In : *IEEE Signal processing magazine* 29.6 (2012), p. 82-97.
- [79] T. HOBZA, D. MORALES et L. PARDO. « Rényi statistics for testing equality of autocorrelation coefficients ». In : *Statistical Methodology* 6.4 (2009), p. 424-436.
- [80] V. HODGE et J. AUSTIN. « A survey of outlier detection methodologies ». In : *Artificial intelligence review* 22.2 (2004), p. 85-126.
- [81] R. HUSSAIN et S. ZEADALLY. « Autonomous cars : Research results, issues, and future challenges ». In : *IEEE Communications Surveys & Tutorials* 21.2 (2018), p. 1275-1313.
- [82] G. INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. « International Organization for Standardization. Statistique – vocabulaire et symboles – partie 2 : Statistique appliquée. Technical Report ISO 3534-2 ». In : (2006).
- [83] M. IRI, K. AOKI, E. O'SHIMA et H. MATSUYAMA. « An algorithm for diagnosis of system failures in the chemical process ». In : *Computers & Chemical Engineering* 3.1-4 (1979), p. 489-493.
- [84] D. ISELE, R. RAHIMI, A. COSGUN, K. SUBRAMANIAN et K. FUJIMURA. « Navigating occluded intersections with autonomous vehicles using deep reinforcement learning ». In : *2018 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE. 2018, p. 2034-2039.
- [85] R. ISERMANN. « Model-based fault-detection and diagnosis–status and applications ». In : *Annual Reviews in control* 29.1 (2005), p. 71-85.
- [86] R. ISERMANN. « Terminology in fault detection and diagnosis ». In : *Combustion Engine Diagnosis*. Springer, 2017, p. 295-297.
- [87] Y. IWASAKI et H. A. SIMON. « Causality in device behavior ». In : *Artificial intelligence* 29.1 (1986), p. 3-32.
- [88] C. JIANG, J. SHEN, S. CHEN, Y. CHEN, D. LIU et Y. BO. « UWB NLOS/LOS classification using deep learning method ». In : *IEEE Communications Letters* 24.10 (2020), p. 2226-2230.

-
- [89] Y. G. JUNG, M. S. KANG et J. HEO. « Clustering performance comparison using K-means and expectation maximization algorithms ». In : *Biotechnology & Biotechnological Equipment* 28.sup1 (2014), S44-S48.
- [90] S. JUSOH et S. ALMAJALI. « A systematic review on fusion techniques and approaches used in applications ». In : *IEEE Access* 8 (2020), p. 14424-14439.
- [91] D.-j. JWO et H.-c. HUANG. « Neural Network Aided Adaptive Extended Kalman Filtering Approach for DGPS Positioning ». In : (2004), p. 449-463. DOI : 10.1017/S0373463304002814.
- [92] R. E. KALMAN. « A new approach to linear filtering and prediction problems ». In : (1960).
- [93] N. KALRA. *Challenges and approaches to realizing autonomous vehicle safety*. RAND Santa Monica, 2017.
- [94] M. KANEKO, K. IWAMI, T. OGAWA, T. YAMASAKI et K. AIZAWA. « Mask-slam : Robust feature-based monocular slam by masking using semantic segmentation ». In : *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*. 2018, p. 258-266.
- [95] M. KANO, T. FUJIOKA, O. TONOMURA, S. HASEBE et M. NODA. « Data-based and model-based blockage diagnosis for stacked microchemical processes ». In : *Chemical engineering science* 62.4 (2007), p. 1073-1080.
- [96] E. D. KAPLAN et C. J. HEGARTY. *Understanding GPS : Principles and Applications*, Norwood, MA : Artech House. 2006.
- [97] H. KAY et B. KUIPERS. « Numerical Behavior Envelopes for Qualitative Models. » In : *AAAI*. 1993, p. 606-613.
- [98] B. KELLY et F. LEES. « The propagation of faults in process plants : 2. Fault tree synthesis ». In : *Reliability Engineering* 16.1 (1986), p. 39-62.
- [99] F. KENDOUL, I. FANTONI et K. NONAMI. « Optic flow-based vision system for autonomous 3D localization and control of small aerial vehicles ». In : *Robotics and autonomous systems* 57.6-7 (2009), p. 591-602.
- [100] B. KHALEGHI, A. KHAMIS, F. O. KARRAY et S. N. RAZAVI. « Multisensor data fusion : A review of the state-of-the-art ». In : *Information fusion* 14.1 (2013), p. 28-44.

- [101] S. KHALID, T. KHALIL et S. NASREEN. « A survey of feature selection and feature extraction techniques in machine learning ». In : *2014 science and information conference*. IEEE. 2014, p. 372-378.
- [102] S. KHASTGIR, H. SIVENCRONA, G. DHADYALLA, P. BILLING, S. BIRRELL et P. JENNINGS. « Introducing ASIL inspired dynamic tactical safety decision framework for automated vehicles ». In : *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*. IEEE. 2017, p. 1-6.
- [103] E. KIM, T. WALTER et J. POWELL. « Adaptive carrier smoothing using code and carrier divergence ». In : *Proc. ION NTM*. 2007, p. 22-24.
- [104] D. P. KINGMA et J. BA. « Adam : A method for stochastic optimization ». In : *arXiv preprint arXiv :1412.6980* (2014).
- [105] J. KLOBUCHAR. « Ionospheric effects on GPS, GPS World ». In : (1991).
- [106] S. KLUGE, K. REIF et M. BROKATE. « Stochastic stability of the extended Kalman filter with intermittent observations ». In : *IEEE Transactions on Automatic Control* 55.2 (2010), p. 514-518.
- [107] D. T. KNIGHT. « Rapid development of tightly-coupled GPS/INS systems ». In : *Proceedings of Position, Location and Navigation Symposium-PLANS'96*. IEEE. 1996, p. 300-305.
- [108] M. KOKAWA, S. MIYAZAKI et S. SHINGAI. « Fault location using digraph and inverse direction search with application ». In : *Automatica* 19.6 (1983), p. 729-735.
- [109] P. KOOPMAN et M. WAGNER. « Challenges in autonomous vehicle testing and validation ». In : *SAE International Journal of Transportation Safety* 4.1 (2016), p. 15-24.
- [110] M. A. KRAMER et B. PALOWITCH JR. « A rule-based approach to fault diagnosis using the signed directed graph ». In : *AIChE journal* 33.7 (1987), p. 1067-1078.
- [111] A. KRISHNAMURTHY, K. KANDASAMY, B. POCZOS et L. WASSERMAN. « Non-parametric estimation of renyi divergence and friends ». In : *International Conference on Machine Learning*. 2014, p. 919-927.
- [112] B. KUIPERS. « Qualitative simulation ». In : *Artificial intelligence* 29.3 (1986), p. 289-338.

-
- [113] S. KULLBACK et R. A. LEIBLER. « On information and sufficiency ». In : *The annals of mathematical statistics* 22.1 (1951), p. 79-86.
- [114] H. KUUSNIEMI, A. WIESER, G. LACHAPPELLE et J. TAKALA. « User-level reliability monitoring in urban personal satellite-navigation ». In : *IEEE Transactions on Aerospace and Electronic Systems* 43.4 (2007), p. 1305-1318.
- [115] S. KUUTTI, R. BOWDEN, Y. JIN, P. BARBER et S. FALLAH. « A survey of deep learning applications to autonomous vehicle control ». In : *IEEE Transactions on Intelligent Transportation Systems* 22.2 (2020), p. 712-733.
- [116] G. LACHAPPELLE. « Lecture notes of GPS Theory and applications ». In : *The University of Calgary, Fall* (1997).
- [117] R. B. LANGLEY. « GPS receiver system noise ». In : *GPS world* 8.6 (1997), p. 40-45.
- [118] O. LE MARCHAND, P. BONNIFAIT, J. BAÑEZ-GUZMÁN, F. PEYRET et D. BETAÏLLE. « Performance evaluation of fault detection algorithms as applied to automotive localisation ». In : *European Navigation Conference-GNSS 2008*. 2008.
- [119] J. LEE, Y.-A. LI, M.-H. HUNG et S.-J. HUANG. « A fully-integrated 77-GHz FMCW radar transceiver in 65-nm CMOS technology ». In : *IEEE Journal of Solid-State Circuits* 45.12 (2010), p. 2746-2756.
- [120] A. LEICK. « GPS Satellite Surveying. John Wiley & Sons ». In : *Inc, USA* (1995).
- [121] W. LI, X. CUI et M. LU. « A robust graph optimization realization of tightly coupled GNSS/INS integrated navigation system for urban vehicles ». In : *Tsinghua Science and Technology* 23.6 (2018), p. 724-732.
- [122] Z. LI, J. WANG, B. LI, J. GAO et X. TAN. « GPS / INS / Odometer Integrated System Using Fuzzy Neural Network for Land Vehicle Navigation Applications ». In : 2014 (2019), p. 967-983. DOI : 10.1017/S0373463314000307.
- [123] J. LIU et G. GUO. « Vehicle localization during GPS outages with extended Kalman filter and deep learning ». In : *IEEE Transactions on Instrumentation and Measurement* 70 (2021), p. 1-10.
- [124] J. LIU, Q. SUN, Z. FAN et Y. JIA. « TOF lidar development in autonomous vehicle ». In : *2018 IEEE 3rd Optoelectronics Global Conference (OGC)*. IEEE. 2018, p. 185-190.

- [125] Y. LU, E. G. COLLINS JR et M. F. SELEKWA. *Parity relation based fault detection, isolation and reconfiguration for autonomous ground vehicle localization sensors*. Rapp. tech. FLORIDA STATE UNIV TALLAHASSEE DEPT OF-MECHANICAL ENGINEERING, 2004.
- [126] R. C. LUO, C.-C. YIH et K. L. SU. « Multisensor fusion and integration : approaches, applications, and future research directions ». In : *IEEE Sensors journal* 2.2 (2002), p. 107-119.
- [127] X. LUO, M. MAYER et B. HECK. « Analysing time series of GNSS residuals by means of AR (I) MA processes ». In : *VII Hotine-Marussi symposium on mathematical geodesy*. Springer. 2012, p. 129-134.
- [128] Y. MA, Z. WANG, H. YANG et L. YANG. « Artificial intelligence applications in the development of autonomous vehicles : a survey ». In : *IEEE/CAA Journal of Automatica Sinica* 7.2 (2020), p. 315-329.
- [129] K. MAKKAWI, N. AIT-TMAZIRTE, M. EL BADAoui EL NAJJAR et N. MOUBAYED. « Adaptive diagnosis for fault tolerant data fusion based on α -rényi divergence strategy for vehicle localization ». In : *Entropy* 23.4 (2021), p. 463.
- [130] J. MARAIS, C. MEURIE, D. ATTIA, Y. RUICHEK et A. FLANCQUART. « Toward accurate localization in guided transport : Combining GNSS data and imaging information ». In : *Transportation Research Part C : Emerging Technologies* 43 (2014), p. 188-197.
- [131] W. S. MCCULLOCH et W. PITTS. « A logical calculus of the ideas immanent in nervous activity ». In : *The bulletin of mathematical biophysics* 5.4 (1943), p. 115-133.
- [132] W. MEI, G. SHAN et C. WANG. « Practical development of the second-order extended Kalman filter for very long range radar tracking ». In : *Signal Processing* 91.5 (2011), p. 1240-1248.
- [133] M. A. de MIGUEL, F. GARCIA et J. M. ARMINGOL. « Improved LiDAR probabilistic localization for autonomous vehicles using GNSS ». In : *Sensors* 20.11 (2020), p. 3145.
- [134] Y. MORALES, E. TAKEUCHI et T. Tsubouchi. « Vehicle localization in outdoor woodland environments with sensor fault detection ». In : *2008 IEEE International Conference on Robotics and Automation*. IEEE. 2008, p. 449-454.

-
- [135] A. G. MUTAMBARA. *Decentralized estimation and control for multisensor systems*. CRC press, 1998.
- [136] A. NOURELDIN, T. B. KARAMAT, M. D. EBERTS et A. EL-SHAFIE. « Performance enhancement of MEMS-based INS/GPS integration for low-cost navigation applications ». In : *IEEE Transactions on vehicular technology* 58.3 (2008), p. 1077-1096.
- [137] A. NOURELDIN, T. B. KARAMAT et J. GEORGY. *Fundamentals of inertial navigation, satellite-based positioning and their integration*. Springer Science & Business Media, 2012.
- [138] A. NOURELDIN, T. B. KARAMAT et J. GEORGY. « Fundamentals of inertial navigation, satellite-based positioning and their integration ». In : (2013).
- [139] M. OBST, S. BAUER, P. REISDORF et G. WANIELIK. « Multipath detection with 3D digital maps for robust multi-constellation GNSS/INS vehicle localization in urban areas ». In : *2012 IEEE Intelligent Vehicles Symposium*. IEEE. 2012, p. 184-190.
- [140] J. PARK, D. LEE et C. PARK. « Implementation of vehicle navigation system using gnss, ins, odometer and barometer ». In : *Journal of positioning, navigation, and Timing* 4.3 (2015), p. 141-150.
- [141] B. PARKINSON. « Introduction and heritage of NAVSTAR, the global positioning system ». In : *Global positioning system : Theory and applications* (1996), p. 3-28.
- [142] N. PATWARDHAN, M. INGALHALIKAR et R. WALAMBE. « ARiA : Utilizing Richard's Curve for Controlling the Non-monotonicity of the Activation Function in Deep Neural Nets ». In : *arXiv preprint arXiv :1805.08878* (2018).
- [143] M. G. PETOVELLO. *Real-time integration of a tactical-grade IMU and GPS for high-accuracy positioning and navigation*. Citeseer, 2003.
- [144] M. G. PETOVELLO. « UCGE Reports Real-Time Integration of a Tactical-Grade IMU and GPS for High-Accuracy Positioning and Navigation by ». In : 20173 (2003).
- [145] M. PETOVELLO et G. LACHAPELLE. « Comparison of vector-based software receiver implementations with application to ultra-tight GPS/INS integration ». In : *Proceedings of ION GNSS*. T. 6. Citeseer. 2006.

- [146] R. PIRNIK, M. HRUBOŠ, D. NEMEC, T. MRAVEC et P. BOŽEK. « Integration of inertial sensor data into control of the mobile platform ». In : *Federated Conference on Software Development and Object Technologies*. Springer. 2015, p. 271-282.
- [147] A. PIRSIAVASH, A. BROUMANDAN, G. LACHAPELLE et K. O'KEEFE. « GNSS code multipath mitigation by cascading measurement monitoring techniques ». In : *Sensors* 18.6 (2018), p. 1967.
- [148] W. RAHIMAN et Z. ZAINAL. « An overview of development GPS navigation for autonomous car ». In : *2013 IEEE 8th Conference on Industrial Electronics and Applications (ICIEA)*. IEEE. 2013, p. 1112-1118.
- [149] O. RAIMAN. « Order of magnitude reasoning ». In : *Readings in qualitative reasoning about physical systems*. Elsevier, 1990, p. 318-322.
- [150] S. RAMASAMY, R. SABATINI, A. GARDI et J. LIU. « LIDAR obstacle warning and avoidance system for unmanned aerial vehicle sense-and-avoid ». In : *Aerospace Science and Technology* 55 (2016), p. 344-358.
- [151] T. G. REID, S. E. HOUTS, R. CAMMARATA, G. MILLS, S. AGARWAL, A. VORA et al. « Localization requirements for autonomous vehicles ». In : *arXiv preprint arXiv :1906.01061* (2019).
- [152] R. RENGASWAMY, D. MYLARASWAMY, K.-E. ÅRZÉN et V. VENKATASUBRAMANIAN. « A comparison of model-based and neural network-based diagnostic methods ». In : *Engineering Applications of Artificial Intelligence* 14.6 (2001), p. 805-818.
- [153] A. RÉNYI et al. « On measures of entropy and information ». In : *Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1 : Contributions to the Theory of Statistics*. The Regents of the University of California. 1961.
- [154] J. J. RISSANEN. « Fisher information and stochastic complexity ». In : *IEEE transactions on information theory* 42.1 (1996), p. 40-47.
- [155] C. RIZOS. « Locata : A positioning system for indoor and outdoor applications where GNSS does not work ». In : *Proceedings of the 18th Association of Public Authority Surveyors Conference*. 2013, p. 73-83.
- [156] H. ROHLING et C. MOLLER. « Radar waveform for automotive radar systems and applications ». In : *2008 IEEE Radar Conference*. IEEE. 2008, p. 1-4.

-
- [157] B. RYSTEDT et L. BENOSA. « Chapitre 1 CARTOGRAPHIE par Bengt Rystedt, Suède Traduction par Laurent Benosa et Dominique Gresle-Pouliny, Relecture d'harmonisation par Felix de Montety 1.1 Introduction ». In : (2014), p. 13-21.
- [158] E. SACKS. « Qualitative analysis by piecewise linear approximation ». In : *Artificial Intelligence in Engineering* 3.3 (1988), p. 151-155.
- [159] H. SAIRO, D. AKOPIAN et J. TAKALA. « Weighted dilution of precision as quality measure in satellite positioning ». In : *IEE Proceedings-Radar, Sonar and Navigation* 150.6 (2003), p. 430-436.
- [160] J. SCHMIDT-HIEBER. « Nonparametric regression using deep neural networks with ReLU activation function ». In : *arXiv preprint arXiv :1708.06633* (2017).
- [161] G. T. SCHMIDT et R. E. PHILLIPS. *INS/GPS integration architectures*. Rapp. tech. MASSACHUSETTS INST OF TECH LEXINGTON MA, 2010.
- [162] B. SCHOETTLE. « Sensor fusion : A comparison of sensing capabilities of human drivers and highly automated vehicles ». In : *University of Michigan* (2017).
- [163] F. SERDIO, E. LUGHOFFER, K. PICHLER, T. BUCHEGGER, M. PICHLER et H. EFENDIC. « Fault detection in multi-sensor networks based on multivariate time-series models and orthogonal transformations ». In : *Information Fusion* 20 (2014), p. 272-291.
- [164] S. SHALEV-SHWARTZ et S. BEN-DAVID. *Understanding machine learning : From theory to algorithms*. Cambridge university press, 2014.
- [165] J. SHAN et C. K. TOTH. *Topographic laser ranging and scanning : principles and processing*. CRC press, 2018.
- [166] N. EL-SHEIMY, K.-W. CHIANG et A. NOURELDIN. « The utilization of artificial neural networks for multisensor system integration in navigation and positioning instruments ». In : *IEEE Transactions on instrumentation and measurement* 55.5 (2006), p. 1606-1615.
- [167] N. EL-SHEIMY, K.-P. SCHWARZ, M. WEI et M. LAVIGNE. « VISAT : a mobile city survey system of high accuracy ». In : *Proceedings of the 8th International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GPS 1995)*. 1995, p. 1307-1315.
- [168] E.-H. SHIN. « Estimation techniques for low-cost inertial navigation ». In : *UCGE report 20219* (2005).

- [169] K. SHUNSUKE, G. YANLEI et L.-T. HSU. « GNSS/INS/on-board camera integration for vehicle self-localization in urban canyon ». In : *2015 IEEE 18th International Conference on Intelligent Transportation Systems*. IEEE. 2015, p. 2533-2538.
- [170] D. SILVER, T. HUBERT, J. SCHRIITWIESER, I. ANTONOGLU, M. LAI, A. GUEZ et al. « A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play ». In : *Science* 362.6419 (2018), p. 1140-1144.
- [171] I. SOBH, L. AMIN, S. ABDELKARIM, K. ELMADAWY, M. SAEED, O. ABDELTAWAB et al. « End-to-end multi-modal sensors fusion system for urban automated driving ». In : (2018).
- [172] A. SOLOVIEV. « Tight coupling of GPS, laser scanner, and inertial measurements for navigation in urban environments ». In : *2008 IEEE/ION Position, Location and Navigation Symposium*. IEEE. 2008, p. 511-525.
- [173] S. SOYLEMEZ et W. D. SEIDER. « A new technique for precedence-ordering chemical process equation sets ». In : *AIChE Journal* 19.5 (1973), p. 934-942.
- [174] N. SUGANUMA et T. UOZUMI. « Precise position estimation of autonomous vehicle based on map-matching ». In : *2011 IEEE Intelligent Vehicles Symposium (IV)*. IEEE. 2011, p. 296-301.
- [175] L. SUN, J. CHEN, K. XIE et T. GU. « Deep and shallow features fusion based on deep convolutional neural network for speech emotion recognition ». In : *International Journal of Speech Technology* 21.4 (2018), p. 931-940.
- [176] Y. SUN. « RAIM-NET : A deep neural network for receiver autonomous integrity monitoring ». In : *Remote Sensing* 12.9 (2020), p. 1503.
- [177] P. SUNDVALL et P. JENSFELT. « Fault detection for mobile robots using redundant positioning systems ». In : *Proceedings 2006 IEEE International Conference on Robotics and Automation, 2006. ICRA 2006*. IEEE. 2006, p. 3781-3786.
- [178] T. SUZUKI et N. KUBO. « Simulation of GNSS satellite availability in urban environments using Google Earth ». In : *Proceedings of the ION 2015 Pacific PNT Meeting*. 2015, p. 1069-1079.
- [179] Z. TAHIR et R. ALEXANDER. « Coverage based testing for V&V and safety assurance of self-driving autonomous vehicles : A systematic literature review ». In : *2020 IEEE International Conference On Artificial Intelligence Testing (AI-Test)*. IEEE. 2020, p. 23-30.

-
- [180] F. TAO, J. CHENG, Q. QI, M. ZHANG, H. ZHANG et F. SUI. « Digital twin-driven product design, manufacturing and service with big data ». In : *The International Journal of Advanced Manufacturing Technology* 94.9 (2018), p. 3563-3576.
- [181] Z. TAO, P. BONNIFAIT, V. FREMONT et J. IBANEZ-GUZMAN. « Lane marking aided vehicle localization ». In : *16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*. IEEE. 2013, p. 1509-1515.
- [182] A. TARTAKOVSKY, I. NIKIFOROV et M. BASSEVILLE. *Sequential analysis : Hypothesis testing and changepoint detection*. CRC Press, 2014.
- [183] S. TAY et J. MARAIS. « Weighting models for GPS Pseudorange observations for land transportation in urban canyons ». In : *6th European workshop on GNSS signals and signal processing*. 2013, 4p.
- [184] M. THOMAS et A. T. JOY. *Elements of information theory*. Wiley-Interscience, 2006.
- [185] D. TITTERTON, J. L. WESTON et J. WESTON. *Strapdown inertial navigation technology*. T. 17. IET, 2004.
- [186] G. TSOUMAKAS et I. KATAKIS. « Multi-label classification : An overview ». In : *International Journal of Data Warehousing and Mining (IJDWM)* 3.3 (2007), p. 1-13.
- [187] A. TURCHIN et D. DENKENBERGER. « Classification of global catastrophic risks connected with artificial intelligence ». In : *Ai & Society* 35.1 (2020), p. 147-163.
- [188] N. H. ULERICH et G. J. POWERS. « On-line hazard aversion and fault diagnosis in chemical processes : the digraph+ fault-tree method ». In : *IEEE Transactions on Reliability* 37.2 (1988), p. 171-177.
- [189] J. VAN BRUMMELEN, M. O'BRIEN, D. GRUYER et H. NAJJARAN. « Autonomous vehicle perception : The technology of today and tomorrow ». In : *Transportation research part C : emerging technologies* 89 (2018), p. 384-406.
- [190] T. VAN ERVEN et P. HARREMOS. « Rényi divergence and Kullback-Leibler divergence ». In : *IEEE Transactions on Information Theory* 60.7 (2014), p. 3797-3820.
- [191] C. VASTRAD et al. « Performance analysis of neural network models for oxazolines and oxazoles derivatives descriptor dataset ». In : *arXiv preprint arXiv :1312.2853* (2013).

- [192] G. VELASCO-HERNANDEZ, J. BARRY, J. WALSH et al. « Autonomous Driving Architectures, Perception and Data Fusion : A Review ». In : *2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP)*. IEEE. 2020, p. 315-321.
- [193] G. VERDIER, N. HILGERT et J.-P. VILA. « Calcul d'un seuil adaptatif pour des algorithmes de type CUSUM ». In : *37èmes Journées de Statistique*. Pau. 2005.
- [194] S. VERMA, Y. H. ENG, H. X. KONG, H. ANDERSEN, M. MEGHJANI, W. K. LEONG et al. « Vehicle detection, tracking and behavior analysis in urban driving environments using road context ». In : *2018 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE. 2018, p. 1413-1420.
- [195] M. VERMEER. « The precision of geodetic GPS and one way of improving it ». In : *Journal of Geodesy* 71.4 (1997), p. 240-245.
- [196] M. L. VISINSKY, J. R. CAVALLARO et I. D. WALKER. « Robotic fault detection and fault tolerance : A survey ». In : *Reliability Engineering & System Safety* 46.2 (1994), p. 139-158.
- [197] T. WALTER et P. ENGE. « Weighted RAIM for precision approach ». In : *PROCEEDINGS OF ION GPS*. T. 8. Institute of Navigation. 1995, p. 1995-2004.
- [198] L. WANG, P. D. GROVES et M. K. ZIEBART. « Smartphone shadow matching for better cross-street GNSS positioning in urban environments ». In : *The Journal of Navigation* 68.3 (2015), p. 411-433.
- [199] R. WANG. « 3D building modeling using images and LiDAR : A review ». In : *International Journal of Image and Data Fusion* 4.4 (2013), p. 273-292.
- [200] Z. WANG, Y. WU et Q. NIU. « Multi-sensor fusion in automated driving : A survey ». In : *Ieee Access* 8 (2019), p. 2847-2868.
- [201] P. W. WARD, J. W. BETZ, C. J. HEGARTY et al. « Satellite signal acquisition, tracking, and data demodulation ». In : *Understanding GPS : principles and applications* (2006), p. 153-241.
- [202] W. WEN, Y. C. KAN et L.-T. HSU. « Performance comparison of GNSS/INS integrations based on EKF and factor graph optimization ». In : *Proceedings of the 32nd International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2019)*. 2019, p. 3019-3032.

-
- [203] J. WENDEL et G. F. TROMMER. « Tightly coupled GPS/INS integration for missile applications ». In : *Aerospace Science and Technology* 8.7 (2004), p. 627-634.
- [204] F. E. WHITE. *Data fusion lexicon*. Rapp. tech. Joint Directors of Labs Washington DC, 1991.
- [205] N. WIENER. « Extrapolation, interpolation and smoothing of stationary time series-with engineering applications' MIT Press ». In : *Google Scholar* (1949).
- [206] A. WIESER et F. K. BRUNNER. « SIGMA-F : variances of GPS observations determined by a fuzzy system ». In : *Vistas for Geodesy in the New Millennium*. Springer, 2002, p. 365-370.
- [207] A. WOO, B. FIDAN et W. W. MELEK. « Localization for autonomous driving ». In : *Handbook of Position Location : Theory, Practice, and Advances, Second Edition* (2018), p. 1051-1087.
- [208] A. WUNDERLICH, B. GOOSSENS et C. K. ABBEY. « Optimal joint detection and estimation that maximizes ROC-type curves ». In : *IEEE transactions on medical imaging* 35.9 (2016), p. 2164-2173.
- [209] M. XIE, L. TRASSOUDAINE, J. ALIZON, M. THONNAT et J. GALLICE. « Active and intelligent sensing of road obstacles : Application to the European Eureka-PROMETHEUS project ». In : *1993 (4th) International Conference on Computer Vision*. IEEE. 1993, p. 616-623.
- [210] G. XUAN, X. ZHU, P. CHAI, Z. ZHANG, Y. Q. SHI et D. FU. « Feature selection based on the Bhattacharyya distance ». In : *18th International Conference on Pattern Recognition (ICPR'06)*. T. 4. IEEE. 2006, p. 957-957.
- [211] W. XUE, Y.-q. GUO et X.-d. ZHANG. « A bank of Kalman filters and a robust Kalman filter applied in fault diagnosis of aircraft engine sensor/actuator ». In : *Second International Conference on Innovative Computing, Informatio and Control (ICICIC 2007)*. IEEE. 2007, p. 10-10.
- [212] D. J. YEONG, G. VELASCO-HERNANDEZ, J. BARRY, J. WALSH et al. « Sensor and sensor fusion technology in autonomous vehicles : A review ». In : *Sensors* 21.6 (2021), p. 2140.
- [213] R. YOZEVITCH, B. B. MOSHE et A. WEISSMAN. « A robust GNSS los/nlos signal classifier ». In : *NAVIGATION : Journal of The Institute of Navigation* 63.4 (2016), p. 429-442.

- [214] D. YUHUA et Y. DATAO. « Estimation of failure probability of oil and gas transmission pipelines by fuzzy fault tree analysis ». In : *Journal of loss prevention in the process industries* 18.2 (2005), p. 83-88.
- [215] F. ZHANG, D. CLARKE et A. KNOLL. « Vehicle detection based on LiDAR and camera fusion ». In : *17th IEEE International Conference on Intelligent Transport Systems (ITSC), Special Session on Advanced Vehicle Active Safety Systems*. 2014.
- [216] Z. ZHANG. « Improved adam optimizer for deep neural networks ». In : *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*. IEEE. 2018, p. 1-2.

Annexes

Annexe A

Les méthodes d'apprentissage

Dans l'apprentissage automatique, les méthodes peuvent se catégoriser selon le type d'apprentissage qu'ils emploient. On peut les classer en trois grandes approches [164] :

- L'apprentissage supervisé
- L'apprentissage non-supervisé
- L'apprentissage par renforcement

A.1 L'apprentissage supervisé

Pour pouvoir appliquer l'apprentissage supervisé, il faut disposer de données étiquetées ou labellisées. Pour obtenir un jeu de données, on considère x_n entrées et les sorties désirées associées y_n . L'objectif est d'entraîner le modèle d'apprentissage choisi à prédire correctement la sortie y pour des nouvelles entrées non étiquetées x , à partir de la connaissance fournie par les n observations étiquetées du jeu de données. Pour répondre à cet objectif, on considère une fonction de prédiction f_w paramétrée par w . La prédiction de l'étiquette de sortie y qui correspond à d'une nouvelle observation x qui ne fait pas partie du jeu de données est défini comme $f_w(x)$. Afin de prédire correctement les labels de sortie, deux phases doivent être réalisées : la phase d'apprentissage, aussi appelée d'entraînement et la phase de test. Dans la première phase, l'ensemble des paramètres w est adapté de manière à optimiser la performance de prédiction basée sur les observations étiquetées, qui représentent une base d'entraînement. Par la suite, la phase de test est entamé. Dans cette phase, la valeur de sortie prédite d'une nouvelle observation x est défini comme $f_w(x)$, en se basant sur les paramètres w obtenu par la phase d'apprentissage. L'évaluation de la méthode d'apprentissage est basée sur une mesure qui minimise l'écart entre les sorties « vraies » étiquettes y_n et les étiquettes prédites $f_w(x_n)$. Le résultat de la prédiction dépend de divers facteurs tel que : le choix de la famille à laquelle appartient la fonction de prédiction, le choix du critère d'optimisation

de w et d'autres facteurs. L'apprentissage supervisé est généralement utilisé pour deux types de problèmes :

- La régression est utilisée lorsque la sortie à prédire peut prendre des valeurs continues, il s'agit d'une variable réelle (y est une valeur scalaire ou vectorielle).
- La classification est une tâche consistant à choisir une classe (y désigne une classe) parmi toutes celles possibles.

Parmi les algorithmes d'apprentissage supervisé classiques, on peut citer l'algorithme de la régression linéaire, la régression logistique et les modèles tels que les réseaux de neurones, les arbres de décision, les forêts aléatoires et les machines à support de vecteur.

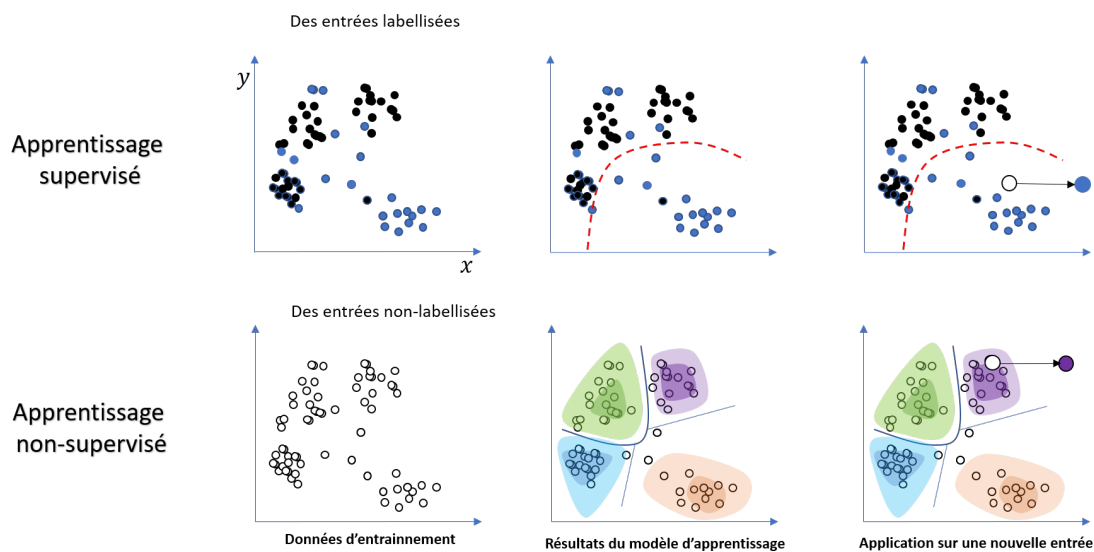


FIGURE A.1 – La différence entre un apprentissage supervisé et non-supervisé

A.2 L'apprentissage non-supervisé

Dans le cas où les données ne sont pas étiquetées, l'apprentissage non-supervisé est utilisé. L'objectif de cette méthode est d'identifier des caractéristiques communes aux observations. L'apprentissage non-supervisé est principalement composé des algorithmes de regroupement, ou de partitionnement (*clustering*), dans lequel l'objectif est d'identifier automatiquement des groupes (ou clusters) d'observations partageant des caractéristiques communes. Ces algorithmes cherchent à séparer les données d'entrée en un nombre donné de groupes. Chaque élément du groupe doit avoir des caractéristiques davantage similaires des éléments du même groupe mais des caractéristiques relativement éloignées de celles des autres groupes. Par conséquent, ces algorithmes regroupent les entrées en familles afin de les étiqueter automatiquement. Généralement, l'identification des groupes partageant un profil commun est basée

sur le calcul d'une distance D entre les observations. Parmi les algorithmes d'apprentissage non-supervisé les plus courants, on peut citer l'algorithme des k -moyennes (*k-means*), l'analyse en composante principale, le DBSCAN, la décomposition en valeurs singulières et certains réseaux de neurones.

La distinction entre l'apprentissage supervisé et non-supervisé est illustrée dans la figure A.1.

A.3 L'apprentissage par renforcement

L'apprentissage par renforcement est une méthode d'apprentissage automatique qui consiste à entraîner un modèle en le faisant interagir avec son environnement. L'agent dispose d'un modèle initial qui doit être optimisé et placé au sein de son environnement (généralement simulé). Il doit alors atteindre son objectif en faisant certaines actions, basée sur des observations, provenant généralement de capteurs. Un système de récompense et de pénalité permet de guider l'agent vers les bonnes actions à réaliser et d'améliorer le modèle utilisé pour la prise de décision. Ce système de récompenses permet de renforcer les bons choix du modèle et pénaliser les mauvais choix. Le modèle est initialisé aléatoirement et adapte sa stratégie en fonction de son expérience durant la phase d'entraînement. Il s'agit d'un fonctionnement itératif. À chaque itération le modèle réalise une tâche et un score lui est attribué en fonction de ses performances. Les paramètres du modèle sont ensuite légèrement modifiés et la tâche est répétée. Un meilleur score oriente le choix des paramètres vers certaines valeurs, assurant que le modèle se rapproche à terme de résultats satisfaisants. Le choix des récompenses et pénalités a un impact important sur les résultats du modèle final.

Par exemple, une méthode d'apprentissage par renforcement a été utilisé pour entraîner l'ordinateur AlphaGo, ayant vaincu le champion du monde du jeu de Go en 2019 [170]. Le modèle avait alors la possibilité de jouer contre lui-même ou contre d'autres machines afin d'apprendre la stratégie à adopter. Récemment, l'efficacité de l'apprentissage par renforcement profond a été exploré pour la navigation et la localisation d'un véhicule autonome. Dans les travaux [84], un algorithme d'apprentissage par renforcement est employé pour gérer les problèmes d'intersection pour une navigation sûre. Les algorithmes d'apprentissage par renforcement ont été souvent utilisé pour l'entraînement d'un modèle. Ce modèle de comportement est complexe et peut être modélisé par un réseau de neurone. L'utilisation d'apprentissage profond (réseaux de neurones) est aujourd'hui majoritaire pour l'apprentissage par renforcement en raison de la complexité des modèles.

L'apprentissage par renforcement est également couramment utilisé pour des problèmes complexes d'optimisation sous contrainte, en attribuant des récompenses en fonction du critère d'optimisation et des pénalités selon les contraintes voulues.

Annexe B

Les repères de références

Les repères de coordonnées sont utilisés pour exprimer la position d'un point par rapport à une certaine référence. Certains repères de coordonnées sont utiles pour la navigation. On définit quatre différents repères important pour la navigation et la localisation d'un véhicule terrestre [138, 185].

B.1 Repère ECI

Le repère inertiel ECI (*Earth Centered Inertial*) est un repère stationnaire (voir figure B.1) dont l'origine est le centre de la Terre. L'axe z est parallèle à l'axe polaire de la Terre ou à l'axe de rotation de l'ellipsoïde de référence. L'axe des x pointe vers l'équinoxe vernal moyen et l'axe y complète le système de coordonnées orthogonales à droite. L'équinoxe vernal est le nœud ascendant entre l'équateur céleste et l'écliptique.




FIGURE B.1 – Le repère inertiel ECI

B.2 Repère ECEF

Dans la localisation et par extension la navigation, différents systèmes de coordonnées peuvent être utilisés pour différents objectifs. Les coordonnées géodésiques sont classiquement utilisées pour localiser des véhicules avec des récepteurs GNSS. Ainsi, les récepteurs GNSS utilisent des coordonnées géodésiques décrivant une position à partir de deux angles et d'une hauteur. La latitude et la longitude sont deux angles par rapport au centre de la terre qui caractérisent la position 2D des véhicules. La latitude est exprimée par rapport à l'équateur. Elle est positive dans l'hémisphère nord et négatif dans l'hémisphère sud. La longitude est relative au méridien de Greenwich. Finalement, la hauteur étant donnée par rapport à un modèle de référence ellipsoïdal de la Terre. Cette référence est souvent le système géodésique WGS 84 puisqu'il est utilisé par le système GPS. C'est système de référence terrestre tridimensionnel exprimant la position en termes de latitude, de longitude et d'altitude. Elles sont basées sur un ellipsoïde de référence qui est une approximation de la forme de la Terre. Comme de nombreuses transformations géométriques sont compliquées, il est nécessaire de procéder à des approximations avec un système de coordonnées cartésiennes approprié.

L'ECEF (*Earth-Center Earth-Fixed*) est un système de coordonnées cartésiennes orthonormé cartésien, centré sur le centre de la Terre. Ce système de coordonnées cartésiennes n'est pas bien adapté aux véhicules se déplaçant à la surface de la Terre : le centre est situé à une distance importante de la zone de navigation et les axes ne sont pas alignés avec le plan horizontal où des simplifications peuvent être faites pour se positionner en 2D. Donc, il est nécessaire d'utiliser un repère local.

B.3 Repère de navigation

Le repère local est également connu sous le nom de repère de navigation (**n-frame**). Le système de coordonnées ENU (*East North Up*) est un système de coordonnées cartésiennes situé à la surface de la Terre. L'axe x (N) pointe vers l'ellipsoïde Nord (voir figure B.2), l'axe z est orthogonal à l'ellipsoïde de référence et pointe vers le haut (U). L'axe y complète le repère orthogonal à droite, et pointe donc vers l'Est (E). Le repère local peut également être appelé ENU. Les principaux avantages de l'utilisation de ce repère sont que les axes coïncident avec le roulis du corps mobile (r), le tangage (p) et le cap (A) lorsque le véhicule se dirige vers le nord sur une route nivelée. Le centre du ENU est l'origine du système de navigation. Le calcul de la transformation du repère ECEF au repère ENU est détaillé dans [44].

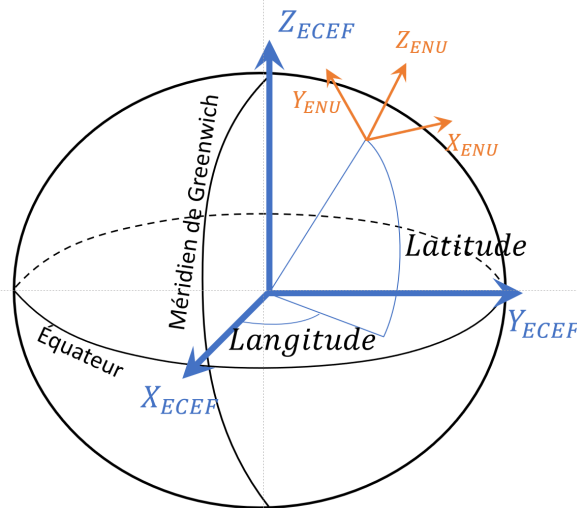


FIGURE B.2 – Position du égo-véhicule e dans un système de coordonnées géodésiques (longitude latitude) ainsi que dans un repère ECEF (X_{ECEF} Y_{ECEF} Z_{ECEF}) et dans un repère ENU (X_{ENU} Y_{ENU} Z_{ENU})

B.4 Repère du véhicule

Le repère du véhicule (*b-frame*) est un cadre orthogonal aligné sur les axes de roulis, de tangage et de cap du véhicule d'une manière particulière. Pour la mise en œuvre du repère de navigation de la ENU les axes x , y et z du repère du véhicule doivent être respectivement alignés sur les axes de roulis, de tangage et de cap (*Yaw*, *Pitch*, *Roll*) du véhicule (voir figure B.3).




FIGURE B.3 – Le repère de la voiture lié au ENU, l'axe z est orthogonal à l'ellipsoïde de référence et pointe vers le haut, l'axe des y tourne d'un angle α dans le sens inverse des aiguilles d'une montre à partir du nord et l'axe des x est orthogonal aux axes des y et des z et forme un repère de coordonnées à droite.