

THESE DE DOCTORAT DE

L'ÉCOLE CENTRALE DE NANTES
COMUE UNIVERSITE BRETAGNE LOIRE

ECOLE DOCTORALE N° 601
*Mathématiques et Sciences et Technologies
de l'Information et de la Communication*
Spécialité : *Signal, Image, Vision*

Par

Fadoua TAIA ALAOU

« Navigation des personnes aux moyens des technologies des smartphones et des données d'environnements cartographiés »

Thèse présentée et soutenue à Nantes, le 10 décembre 2018

Unité de recherche : Laboratoire GEOLOC de l'Institut Français des Sciences et Technologies des Transports, de l'Aménagement et des Réseaux

Rapporteurs avant soutenance :

Latifa Oukhellou Directrice de recherche à l'ISTTAR
Bertrand Merminod Professeur à l'Ecole Polytechnique de Lausanne

Composition du Jury :

Président : Latifa Oukhellou Directrice de recherche à l'ISTTAR
Examineurs : Hassen Fourati Maître de conférences UGA, Equipe système et commandes en réseaux
Mathieu Lagrange Chargé de recherche CNRS au sein du laboratoire LS2N à Nantes
Dir. de thèse : Valérie Renaudin Directrice de recherche IFSTTAR Nantes
Co-dir. de thèse : David Bétaille Directeur de recherche IFSTTAR Nantes

Titre : Navigation des personnes aux moyens des technologies des smartphones et des données d'environnements cartographiés

Mots clés : Navigation inertielle, reconnaissance automatique, détection en ligne, cartographie indoor, filtrage particulière, fusion de données

Résumé : La navigation inertielle grâce aux capteurs intégrés dans les smartphones permet d'assurer une géolocalisation continue même en absence de signal GNSS. Ces capteurs bas coût délivrent néanmoins des mesures bruitées qui engendrent une dérive de la trajectoire. La technique PDR qui est une technique de navigation inertielle par détection de pas souffre de deux limites principales. La première est l'estimation de la longueur de pas car cette dernière dépend des caractéristiques physiques de chaque utilisateur, et la seconde est le résultat d'une dérive angulaire combinée avec un biais lié au portage du capteur à la main. Dans le contexte du projet HAPPYHAND, ce travail s'intéresse à l'exploitation de la carte pour corriger ces différentes erreurs.

Un réseau de navigation topologique est exploité pour corriger à la fois les erreurs angulaires et calibrer le modèle de longueur de pas. Ce modèle est ensuite augmenté par un processus de mise à jour de position par détection de points d'intérêt.

Title : Smartphone based pedestrian navigation using navigation maps

Keywords : Inertial navigation, context awareness, online detection, indoor mapping, particle filtering, data fusion

Abstract :

Smartphone navigation using the low-cost embedded sensors in off the shelf smartphones can provide a continuous solution in GNSS-denied environments. The most widely adopted approach is Pedestrian Dead Reckoning (PDR) that uses acceleration and angular velocity to estimate the user's position. Yet, consumer grade sensors deliver noisy measurements that may result into a drift in the estimated trajectory. One major challenge is to estimate accurately step length information since it depends on physiological features that are specific to each user. In addition, angular biases are more likely to be introduced in the orientation estimation process with handheld devices. This is mainly due to the high degree of freedom of hand motion.

In the context of a national project called HAPPYHAND, the main goal of this work is to exploit map information as far as possible in order to mitigate the previous inherent limitations to the PDR approach. First, a topological network extracted from the map is proposed in order to correct the angular errors and calibrate the step length model. Second, context awareness is adopted in order to provide regular and frequent position updates thanks to a point of interest online detection scheme.

REMERCIEMENTS

Au terme de ce travail, je voudrais remercier toutes les personnes qui m'ont aidé à aller jusqu'au bout de cette thèse et de ce manuscrit.

Je remercie Mme Valérie Renaudin pour m'avoir accueilli au sein du laboratoire GEOLoc, pour m'avoir accompagné dans mes travaux de recherche et m'avoir aidé sur le plan administratif.

Je remercie au même titre M. David Bétaille pour son aide scientifique, sa bienveillance et son soutien continu.

Je voudrais également remercier M. Cyril Ray et M. Mathieu Lagrange pour avoir accepté de m'accompagner durant ces trois années en faisant partie de mon comité de suivi de thèse.

Mes remerciements sont aussi adressés à Mme Latifa Oukhellou et à M. Bertrand Merminod pour le temps qu'ils ont accordé à la lecture et à la critique de ce mémoire, ainsi qu'à l'ensemble des membres du jury dont M. Hassen Fourati.

Au cours de ces années, j'ai eu la chance de travailler auprès de personnes qui m'ont appris des choses, qui m'ont soutenu et qui ont rendu les journées de travail plus agréables. Je pense à Mahdi, Christophe, Mathieu, et plus récemment à Johan, Céline, Aigul, et... la liste est longue ! Alors je remercie toutes ces personnes qui se reconnaîtront pour leur temps et pour leur sympathie.

A tout lecteur.

SOMMAIRE

I. INTRODUCTION	11
I.1 Positionnement de la thèse dans le cadre du projet HAPPYHAND	11
I.1.1 Calcul d'itinéraire adapté à un profil de mobilité	11
I.1.2 Navigation inertielle assistée par la carte	11
I.2 Verrous scientifiques	12
I.2.1 Dérive angulaire	12
I.2.2 Défaut d'alignement entre cap de marche et orientation du capteur	12
I.2.3 Erreurs de distance	13
I.3 Contributions	13
I.4 Organisation du mémoire	13
II. NAVIGATION AUTONOME GRACE AUX MESURES INERTIELLES OU GNSS	16
II.1 Les capteurs MEMS	16
II.1.1 Technologie MEMS et capteurs inertiels et magnétiques embarqués	16
II.1.2 Modélisation des erreurs d'une centrale IMMU	18
II.1.3 Analyse de la variance d'Allan	19
II.2 Calcul de position par méthode de navigation à l'estime (PDR)	21
II.2.1 Détection de pas	21
II.2.2 Estimation de la longueur de pas	22
II.2.3 Calcul d'attitude de l'IMMU	23
II.3 Données GNSS	27
II.3.1 Mesures	27
II.3.2 Aides GNSS pour la navigation dans les milieux masqués	30
II.3.3 Calcul de position GNSS	30
III. MODELES CARTOGRAPHIQUES POUR LA LOCALISATION	34
III.1 Contenu et formats natifs des cartes (Vecteur, Raster)	34
III.1.1 Eléments de la carte significatifs du point de vue des déplacements piétons	34
III.1.2 Différents formats de la carte	38
III.2 Réseaux de navigation	42
III.2.1 Graphe de navigation	42
III.2.2 Mesh de navigation	43
III.2.3 Bilan sur l'utilisation de mesh et de graphes de navigation	44
III.3 Nouveau graphe dans les espaces non-contraints par les obstacles	45
III.3.1 Difficultés de modélisation des espaces non-contraints par les obstacles	45
III.3.2 Adaptation de la notion de portail pour la construction du graphe	45
III.3.3 Génération d'un graphe basé sur les portails	46
IV. LIAISON ENTRE LA CARTE ET LA SIGNATURE DE MOUVEMENT	49
IV.1 Etat de l'art sur les méthodes d'exploitation de la carte pour la localisation	49
IV.1.1 Carte de chaleur traduisant une probabilité d'occupation de la carte	49
IV.1.2 Adaptation des modèles dynamiques à la nature du mouvement	49

IV.1.3	Mesure de position grâce à des points d'intérêt (POI)	50
IV.1.4	Correction de la trajectoire par assimilation avec des itinéraires pré-calculés	50
IV.2	Focus sur les défis de la transition indoor-outdoor	51
IV.2.1	Intérêt de la distinction indoor-outdoor (IO)	51
IV.2.2	Définition de l'indoor et de l'outdoor dans l'état de l'art	52
IV.2.3	Technologies de détection IO existantes	53
IV.2.4	Le problème de généralisation	55
IV.3	Principales méthodes de classification supervisée	56
IV.3.1	Formulation du problème de classification	56
IV.3.2	Algorithmes de classification	61
IV.3.3	Algorithmes de sélection des descripteurs pertinents	63
IV.4	Méthodologie proposée pour la mise à jour de position grâce à des POIs	67
IV.4.1	Approche proposée	67
IV.4.2	Typologie des POIs à partir d'une classification de mouvement	69
IV.4.3	Collecte des signaux	72
IV.4.4	Indexation du signal	74
IV.4.5	Calcul des descripteurs	80
IV.4.6	Variabilité des longueurs de fenêtres dans le processus de détection	82
V.	HYBRIDATION CARTE-IMMU-MAGNETOMETRE-BAROMETRE	84
V.1	Théorie du filtrage Bayésien	84
V.1.2	Filtrage Bayésien	85
V.1.3	Résolution des équations du filtrage Bayésien	86
V.2	Etat de l'art : Méthodes de fusion des données de la carte avec les signaux	89
V.2.1	Utilisation d'un graphe avec un filtre de Kalman	89
V.2.2	Utilisation d'un graphe avec un filtre particulière	92
V.2.3	Utilisation d'un espace borné avec un filtre de Kalman	93
V.2.4	Utilisation d'un espace borné avec un filtre particulière	93
V.3	Conception du filtre particulière réalisant le calcul de position	95
V.3.1	Initialisation	95
V.3.2	Modèle de propagation	96
V.3.3	Mise à jour	98
V.3.4	Ré-échantillonnage	99
V.3.5	Intégration des POIs	100
VI.	EVALUATION EXPERIMENTALE DES PERFORMANCES	103
VI.1	Reconnaissance de mouvement	103
VI.1.1	Descripteurs retenus	103
VI.1.2	Evaluation statistique des résultats de la classification	108
VI.2	Calcul de position	118
VI.2.1	Scénarios d'acquisitions	118
VI.2.2	Evaluation numérique et qualitative des résultats de localisation	120
VI.3	Conclusions	128

VII. CONCLUSION GENERALE	131
VIII. PERSPECTIVES	133
I. ANNEXE 1 : PROBABILITES CONDITIONNELLES	142
I.1 Loi d'une Variable Aléatoire Continue (VAC)	142
I.2 Espérance d'une VAC	142
I.3 Support d'une VAC	142
I.4 Lois conjointe et marginale	142
I.5 Probabilité conditionnelle et loi de Bayes	143
I.6 Espérance conditionnelle	143
I.7 Indépendance conditionnelle	144
I.8 Loi des probabilités totales	144
II. ANNEXE 2 : DETAILS DES ALGORITHMES DE CLASSIFICATION	145
II.1 Random Forest	145
II.1.1 Principe des arbres de décision	145
II.1.2 Critères d'homogénéité	145
II.1.3 Création des branches à partir d'un nœud/descripteur	147
II.1.4 Arbres de décision usuels : ID3, C4.5 et CART	148
II.1.5 Le Bagging	149
II.1.6 Spécificités de l'algorithme RF	150
II.2 Réseaux de neurones	150
II.2.1 Notations	150
II.2.2 Fonctionnement d'un neurone	151
II.2.3 Apprentissage avec un réseau de neurones (Artificial Neural Network : ANN)	152
II.3 Séparateurs à Vaste Marge (SVM)	153
II.3.1 Définitions	153
II.3.2 SVM linéaires	155
II.3.3 SVM non linéaires	157

Liste des figures

Figure 1 : Illustration du principe PDR: la trajectoire est constituée par la suite des segments verts qui ont chacun pour origine la position d'un pied, pour orientation le cap de marche, et pour distance la longueur de pas [2]	12
Figure 2 : Différence entre direction de marche et attitude du capteur porté en main. Ces deux directions sont généralement confondues dans l'état de l'art.	13
Figure 3: Schéma simplifié d'un accéléromètre. Ce dernier est modélisé par une masse m suspendue entre deux ressorts rigidement liés à la masse m et aux faces 1 et 2. Ils ont une raideur k et un coefficient de frottement f . Le déplacement L résultant du mouvement du support de l'accéléromètre est mesuré grâce à des capteurs capacitifs. La valeur du déplacement L est proportionnelle à l'accélération que subit le support suivant son axe de mesure. Cette mesure correspond à la force spécifique par unité de masse de l'accéléromètre car elle n'intègre pas les effets gravitationnels [7].	16
Figure 4: Vue microscopique d'un accéléromètre MEMS. La masse en suspension correspond à la poutre centrale 'beam'. Les lamelles blanches 'Fixed plates' correspondent aux différentes faces de la Figure 3. Ils servent pour la partie électronique permettant de mesurer le déplacement de la masse. Elles sont fixées au support par des 'anchors'. La suspension élastique ou ressort est assurée par les 'tethers' à gauche de l'image. [7]	17
Figure 5: Vue globale d'un accéléromètre MEMS. Le capteur à proprement dit correspond à la partie centrale de l'image où l'on voit la masse centrale, le système de condensateurs et les suspensions sur les bords. [7]	17
Figure 6: Principe de fonctionnement d'un gyromètre MEMS à une masse vibrante. [9]	17
Figure 7: Inspirée de [1], Section : 'Error Characteristics'	18
Figure 8: Pattern de l'accélération et détection de pic par seuillage [16]	22
Figure 9: Modélisation de la marche humaine : pendule inverse [24]	23
Figure 10: Double différence pour déterminer les ambiguïtés entières [31]	31
Figure 11: Largeur accessible par profil de mobilité [33]	34
Figure 12: Liste ordonnée des critères impliqués dans le choix d'un trajet [34]	37
Figure 13: Graphique réalisé à partir des données de l'étude [40] sur les éléments cartographiques importants pour la navigation des personnes mal voyantes.	37
Figure 14: Typologie des voies piétonnes [33]	38
Figure 15: Superposition de photographie aérienne avec des tags et des éléments vectoriels de routes sur Google Maps	39
Figure 16: Photographie aérienne de l'IGN [43]	39
Figure 17 : Objet polygonal représentant un bâtiment	41
Figure 18 : Données attributaires décrivant l'objet « bâtiment »	41
Figure 19 : Objet ponctuel représentant soit un arbre soit un banc	41
Figure 20 : Données attributaires décrivant l'objet ponctuel	41
Figure 21 : Objet linéaire décrivant une voie	41
Figure 22 : Données attributaires décrivant l'objet linéaire « voie »	41
Figure 23: Capture d'un plan CAD	41
Figure 24: Cartographie intérieure dans OSM	42
Figure 25: Extrait Google Maps d'une représentation en 2.5D de la Gare Montparnasse. On peut visualiser les tags 'Entrée/Sortie' ainsi que 'Parking handicapé'. À droite, il est possible	

d'indiquer le numéro d'étage que l'on souhaite visualiser.....	42
Figure 26: Transformation d'un plan d'intérieur en graphe de navigation [54].....	43
Figure 27: Représentation sous forme de graphe d'un bâtiment en 2.5D [55].....	43
Figure 28 : Trottoirs et passages piétons (pointillés noirs) [56]	43
Figure 29 : Maillages réguliers carré et hexagonal [59].....	44
Figure 30 : Maillages irréguliers sous forme de tessellation triangulaire et trapézoïdale [59]	44
Figure 31: Exemple de carte Bitmap (raster) où les pixels navigables sont blancs et les autres noirs [62].....	44
Figure 32 : Exemple de Mesh de navigation [63].....	44
Figure 33 : Scènes de décision et portails dans [56].....	46
Figure 34 : Bordure réglementaire entre une voie cyclable et une voie piétonne	46
Figure 35 : Le graphe de navigation correspond à l'ensemble des itinéraires bleus et rouges. Les parties sélectionnées en rouge sont exploitée dans le texte pour expliquer le principe de construction du graphe.....	47
Figure 36: Carte de probabilité d'occupation en fonction de la classe de mouvement [66].....	49
Figure 37: Détection des coins de bâtiment sur le signal du gyromètre	50
Figure 38: Calcul de polyligne 3D à l'aide de capteurs inertiels et d'un baromètre [70]	50
Figure 39: Détection de POIs par analyse de la trajectoire PDR [70].....	51
Figure 40: Pondération des segments en fonction de la correspondance avec la polyligne reconstruite [70].....	51
Figure 41 : Définition de l'indoor, outdoor et du semi-outdoor dans [72].....	52
Figure 42 : Distinction de quatre types d'environnements dans [73].....	53
Figure 43 : Graphe de transition WIFI [79]. Les nœuds noirs correspondent aux espaces indoor tandis que les autres correspondent à l'outdoor	54
Figure 44 : Distribution des états {indoor, outdoor} selon la classe d'activité du piéton.....	55
Figure 45 : Compromis Biais-Variance d'un prédicteur en fonction de sa complexité [83].....	58
Figure 46 : Répartition des individus labellisés pour les étapes d'apprentissage et de test. Si la validation croisée est réussie, l'ensemble de ces individus sont utilisés pour calculer le modèle final afin de l'évaluer sur des données de validation.	59
Figure 47 : Matrice de confusion pour évaluer la performance d'un classifieur [84]	60
Figure 48 : Métriques usuelles pour l'évaluation de performance d'un classifieur [86].....	60
Figure 49 : Exemple d'un réseau de neurone [88].....	62
Figure 50 : Ces deux nuages de points correspondent à la visualisation de deux classes indiquées par deux couleurs différentes. L'axe horizontal correspond à un attribut 1 et l'axe vertical à un attribut 2. A gauche, les deux classes sont bien séparées dans l'espace des attributs. A droite les deux classes se recouvrent [91].....	64
Figure 51 : Groupes de méthodes pour la sélection des descripteurs [92]	65
Figure 52 : Nuage d'individus selon deux descripteurs (Length, Width) et axes de la PCA [95].....	66
Figure 53 : Nuage d'individus exprimés selon la nouvelle base donnée par les deux axes de la PCA [95].....	66
Figure 54 : Trame de traitement pour l'apprentissage supervisé.....	69
Figure 55 : Schéma de classification simplifié	71
Figure 56 : Typologie des POI en fonction des classes de mouvement	72
Figure 57 : Centrale inertielle et magnétique ULISS	72

Figure 58 : Site géographique où la collecte de signal a eu lieu.....	74
Figure 59 : Signature du gyromètre au moment d'un franchissement de porte battante. (4.9s-7s).....	75
Figure 60 : Signal d'accélération en mode statique (entre 3 et 12s) puis dans un ascenseur (régime permanent entre 25 et 40 s).....	76
Figure 61 : Motif d'accélération lors d'une ouverture manuelle de porte battante (entre 6 et 9 s).....	76
Figure 62 : Signal d'accélération pendant la marche.....	76
Figure 63 : Signal brut de la pression pour une montée d'ascenseur.....	77
Figure 64 : Montée d'ascenseur (19s-24s).....	77
Figure 65 : Montée d'escaliers (11s-18s).....	78
Figure 66 : Signature de pression présentée dans [80] par un smartphone posé au sol.....	78
Figure 67 : Absence de signature de pression pour l'accès au bâtiment par une porte automatique glissante (10s-12s).....	79
Figure 68 : Motif d'accélération associé à l'accès au bâtiment par une porte automatique glissante (10s-12s).....	79
Figure 69: EKF multi-hypothèses pour explorer un graphe de navigation [55].....	90
Figure 70: Map-matching en amont de l'application d'un UKF [68].....	91
Figure 71: Calibration des caps de marche par map-matching [68].....	91
Figure 72: Evolution d'une particule sur un arc : la direction PDR et celle de l'arc présentent un écart inférieur à 10 [112].....	92
Figure 73: Les particules rouges explorent le graphe. Celles qui ont un poids important (entourée en bleu foncé) sont celles qui se trouvent sur le segment dont l'orientation est la plus proche du cap mesuré et qui sont les plus proches de la position GNSS (croix verte) [113].....	93
Figure 74: Filtre particulaire appliqué à une route bornée et des capteurs inertiels et GNSS [115].....	94
Figure 75: Evitement d'obstacles dans un espace borné à l'aide d'un filtre particulaire [116].....	95
Figure 76: Destruction de particules traversant un mur [116].....	95
Figure 77: Cartographie des obstacles et prise en compte des orientations des couloirs [117].....	95
Figure 78 : Initialisation par map-matching d'une position GNSS.....	96
Figure 79 : Orientation des arcs du graphe.....	96
Figure 80 : Test de transition pour le calcul de la variable Dp	98
Figure 81 : Variance expliquée par chacun des 10 premiers axes de la PCA.....	104
Figure 82 : Coefficients de corrélation au carré des descripteurs avec les axes de la PCA (Première partie).....	106
Figure 83 : Coefficients de corrélation au carré des descripteurs avec les axes de la PCA (Deuxième partie).....	106
Figure 84 : Descripteurs retenus par seuillage du coefficient de corrélation au carré des descripteurs avec les axes de la PCA.....	106
Figure 85 : Descripteurs retenus après réduction des corrélations.....	107
Figure 86 : Score de Fisher pour chaque descripteur.....	108
Figure 87 : Information mutuelle pour chaque descripteur.....	108
Figure 88 : Valeurs de précision globale et de macro-moyennes de précision et de sensibilité pour chaque algorithme.....	117
Figure 89 : Acquisition dans un mode Texting.....	118
Figure 90 : Scénario d'acquisition avec des POI.....	119
Figure 91 : Trajet planifié en rouge.....	119

Figure 92 : Zoom sur le début et la fin de l'acquisition	119
Figure 93 : Scénario 1	119
Figure 94 : Scénario 2	119
Figure 95 : Trajectoire corrigée avec des POIs régulièrement détectés.....	120
Figure 96 : La trajectoire de référence est donnée en vert, la trajectoire estimée par filtrage est en rouge et la trajectoire obtenue par le modèle PDR en cyan.	123
Figure 97 : Zoom sur la partie indoor	123
Figure 98 : Histogramme des erreurs calculées par comparaison des positions de référence avec les positions filtrées.....	123
Figure 99 : Facteur d'échelle correctif du modèle de longueur de pas affiché en fonction du temps..	124
Figure 100 : Valeurs correctives du biais angulaire entre l'orientation de ULISS et le cap de marche (orientation des couloirs)	124
Figure 101 : Trajectoire estimée pour le premier scénario (Texting).....	125
Figure 102 : Trajectoire estimée pour le second scénario (Texting).....	125
Figure 103 : Trajectoire estimée pour le troisième scénario (Texting, Swinging).....	126
Figure 104 : Distribution de l'erreur planimétrique pour chaque acquisition.....	126
Figure 105 : Défaut d'alignement angulaire estimé pour le premier trajet	127
Figure 106 : Défaut d'alignement angulaire estimé pour le deuxième trajet	127
Figure 107 : Défaut d'alignement angulaire estimé pour le troisième trajet	128
Figure 108 : Terminologie des arbres de décision.....	145
Figure 109 : Points de coupure pour partitionner le nœud/descripteur A après tri des individus dans l'ordre croissant [122].....	148
Figure 110 : Structure d'un arbre de décision construit par l'algorithme CART	149
Figure 111 : Principe du Bagging dans le cas de la classification [125].....	150
Figure 112 : Notations pour les variables de transfert entre deux couches.....	151
Figure 113 : Fonctionnement d'un neurone	152
Figure 114 : SVM à marge douce [129].....	157

Liste des abréviations

ACP	IO
Analyse en Composantes Principales	Indoor-Outdoor
AHP	K-NN
Analytic Hierarchy Process	K-Nearest Neighbors
ANN	LDA
Artificial Neural Network	Linear Discriminant Analysis
BDD	MEMS
Base de Données	MicroElectroMechanical Sensors
BIM	MI
Building Information Model	Mutual Information
CAD	OSM
Computer Assisted Design	Open Street Map
CAO	PC
Conception Assistée par Ordinateur	Principal Component
CCA	PCA
Canonical Correlation Analysis	Principal Component Analysis
DGNSS	PMR
Differential GNSS	Personne à Mobilité Réduite
DGPS	POI
Differential GPS	Point Of Interest
Dim	PRN
Dimension	Pseudo-Random Noise
EKF	RF
Extended Kalman Filter	Random Forest
FS	RGB
Fisher Score	Red Green Blue
GNSS	RGP
Global Navigation Satellite System	Réseau GNSS Permanent
GPS	RSS
Global Positioning System	Radio Signal Strength
HDOP	RSSI
Horizontal Dilution Of Precision	Received Signal Strength Indication
IMMU	SF
Inertial and Magnetic Measurement Unit	Score de Fisher

SIG

Système d'Information Géographique

SNR

Signal to Noise Ratio

SVM

Support Vector Machine

TTF

Time to First Fix

UKF

Unscented Kalman Filter

ULISS

Ubiquitous Localization unit with Inertial
Sensors and Satellites,

Chapitre I

I. INTRODUCTION	11
I.1 Positionnement de la thèse dans le cadre du projet HAPPYHAND	11
I.1.1 Calcul d'itinéraire adapté à un profil de mobilité	11
I.1.2 Navigation inertielle assistée par la carte	11
I.2 Verrous scientifiques	12
I.2.1 Dérive angulaire	12
I.2.2 Défaut d'alignement entre cap de marche et orientation du capteur	12
I.2.3 Erreurs de distance	13
I.3 Contributions	13
I.4 Organisation du mémoire	13

I. Introduction

I.1 Positionnement de la thèse dans le cadre du projet HAPPYHAND

I.1.1 Calcul d'itinéraire adapté à un profil de mobilité

Cette thèse prend place dans le cadre du projet HAPPYHAND visant à développer une solution de navigation et d'assistance à la mobilité pour les piétons, en particulier les Personnes à Mobilité Réduite (PMR). En effet, à ce jour ces personnes préfèrent se déplacer avec leur propre véhicule même pour de courtes distances afin d'éviter les aléas de la navigation piétonne considérés potentiellement dangereux. Bien que des solutions de géolocalisation et de planification d'itinéraire pour piétons existent aujourd'hui, elles ne suffisent pas pour réduire le sentiment d'insécurité chez les PMR principalement du fait que les dangers ne peuvent toujours être anticipés. La raison principale en est que le niveau de cartographie des villes reste assez bas en matière de mobilier urbain et d'obstacles à la mobilité. Dans une optique d'encouragement des modes de déplacements doux et d'équité, un service de planification d'itinéraire et de géolocalisation prenant en compte le profil de mobilité de l'utilisateur est recherché. Pour ce faire, le projet HAPPYHAND s'intéresse à une optimisation d'itinéraire s'appuyant à la fois sur une cartographie fine de l'espace urbain et des intérieures des bâtiments publics, mais aussi sur une base de données exhaustive des contraintes à la mobilité propres à chaque catégorie de handicap. L'objectif final consiste à développer une application mobile prenant comme requête le point de départ et le point d'arrivée de l'utilisateur, ainsi que son profil de mobilité, et lui fournissant un itinéraire optimal vis-à-vis de ses capacités motrices ainsi que sa position en temps réel. Dans ce contexte d'étude, la carte constitue une pièce maîtresse car elle détermine les choix techniques entrepris pour améliorer la localisation du piéton.

I.1.2 Navigation inertielle assistée par la carte

A ce stade, il est important de noter que cette thèse s'intéresse aussi à l'hypothèse où l'utilisateur décide de poursuivre un chemin autre que l'itinéraire optimal proposé par l'application prévue dans le projet HAPPYHAND. Sont pris en compte les trajets non-contraints par une destination précise et inconnus a priori, ce qui traduit le libre arbitre de l'utilisateur ainsi que les aléas qui en découlent. Avant de détailler les verrous scientifiques adressés dans cette recherche, rappelons d'abord que notre objectif consiste à mettre en place un algorithme de géolocalisation permettant de fournir à l'utilisateur, potentiellement une PMR, sa position en temps réel malgré l'absence de signal GNSS. Cela signifie entre autres que les exigences de précision sur les positions délivrées sont plus ou moins fortes en fonction du profil de mobilité de l'utilisateur.

D'un point de vue technologique, la solution doit exploiter principalement les capteurs inertiels bas coût intégrés dans les smartphones disponibles sur le marché, c'est-à-dire des capteurs de technologie MEMS (MicroElectroMechanical Sensors) appartenant à la gamme « consommateur » [1]. Pour ce faire, le calcul de position se fait par méthode de navigation à l'estime basée sur une technique de détection de pas, communément appelée PDR (Pedestrian Dead Reckoning). Cette méthode utilise principalement les données d'accélération (accéléromètre) et de vitesses angulaires (gyromètre) permettant d'estimer des longueurs de pas et des directions de marche et de calculer la trajectoire du piéton dans une approche de point lancé (Figure 1).

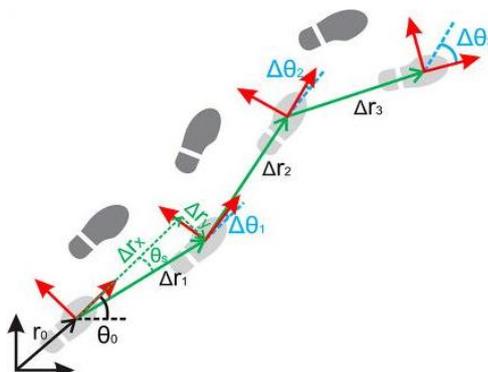


Figure 1 : Illustration du principe PDR: la trajectoire est constituée par la suite des segments verts qui ont chacun pour origine la position d'un pied, pour orientation le cap de marche, et pour distance la longueur de pas [2]

I.2 Verrous scientifiques

I.2.1 Dérive angulaire

Bien qu'assurant la continuité de la solution de navigation en absence de GNSS, les méthodes PDR entraînent une dérive importante des trajectoires à cause de l'accumulation temporelle des bruits des capteurs (notamment la dérive gyroscopique car les vitesses angulaires sont intégrées pour résoudre l'orientation du système). Par conséquent, des mises à jour fréquentes, pas toujours possibles selon l'endroit et le mode de portage du capteur, sont nécessaires pour réduire cet effet d'accumulation d'erreurs. Notons qu'un moyen de calibration classique consiste à imposer des vitesses nulles au moment du contact du pied avec le sol (Zero Velocity Update [3]). Cependant, cette calibration n'est possible que quand le capteur est porté au pied. En ce qui concerne cette thèse où le capteur est porté à la main, d'autres sources de mesures sont nécessaires pour corriger la dérive. La source de mesure supplémentaire ici est la carte.

I.2.2 Défaut d'alignement entre cap de marche et orientation du capteur

Afin de donner une dimension absolue à la trajectoire calculée, il est nécessaire d'exprimer cette dernière dans un repère absolu, par exemple le repère de navigation qui est lié à la carte (Est, Nord géographique, Hauteur ellipsoïdale). Le cap de marche correspond ainsi à la direction du déplacement par rapport au Nord géographique. Théoriquement, si l'attitude du repère anatomique lié au centre de masse du piéton est connue par rapport au repère de navigation, alors le cap de marche en est déduit. En pratique, les mesures réalisées avec un capteur tenu en main ne traduisent pas le déplacement du centre de masse du piéton mais plutôt les mouvements de la main. Cela introduit un bras de levier variable qui peut avoir un impact négatif sur le calcul d'orientation (Figure 2). Par simplification, la plupart des algorithmes PDR substituent l'attitude du capteur à celle du centre de masse du piéton. Cette simplification est valable pour le scénario dit « Texting » où le piéton tient son smartphone droit devant lui, c'est-à-dire où le repère lié au capteur est approximativement aligné avec le repère anatomique lié au piéton. De manière analogue, le calcul d'orientation s'appuie parfois sur une hypothèse de stationnarité du capteur par rapport au repère lié au piéton (ex. attaché à la ceinture, auquel cas le bras de levier entre le centre de mesure du capteur et le centre de masse du piéton est constant). Hormis ces deux cas de figures, l'estimation du cap de marche est biaisée et ce biais nécessite d'être traité à tout instant.

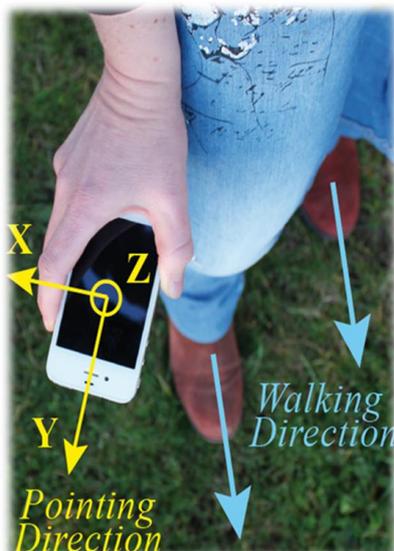


Figure 2 : Différence entre direction de marche et attitude du capteur porté en main. Ces deux directions sont généralement confondues dans l'état de l'art.

I.2.3 Erreurs de distance

Parallèlement à ces erreurs angulaires, les méthodes PDR utilisent des modèles imparfaits de détection et d'estimation de longueur de pas. En effet, ces derniers doivent prendre en compte le mécanisme de marche propre à chaque utilisateur (II.2.2), or il s'agit souvent de modèles génériques qui nécessitent d'être calibrés a posteriori. Outre ce manque de calibration, des pas peuvent être sous/sur détectés. L'estimation de distance s'en trouve alors impactée avec une erreur cumulable agissant directement sur l'estimation de position.

I.3 Contributions

Après cet aperçu sur les limites de la localisation PDR avec un capteur porté à la main, il devient clair que les améliorations majeures dans ce travail concernent l'estimation de distance et les différentes erreurs angulaires. Pour y parvenir, nous avons à disposition les données de la carte et éventuellement le signal GNSS, ce qui limite le cadre de nos investigations de l'état de l'art et détermine nos contributions listées ci-dessous :

- Détermination des erreurs de détection de pas.
- Calibration du modèle de longueur de pas grâce aux données de la carte et GNSS. Cette calibration reste exploitable après perte du signal GNSS.
- Distinction de la dérive angulaire du défaut d'alignement dû au mode de portage du dispositif à la main. Ce dernier est estimé à chaque instant de pas.
- Extension de l'exploitabilité de la carte aux zones non contraintes par les obstacles.
- Définition d'une typologie de points d'intérêt pouvant être généralisée à tout environnement à travers une classification de mouvement (indépendance par rapport aux valeurs de champ magnétique, aux valeurs de pression, valables en extérieur et en intérieur, indépendance par rapport à l'architecture du bâtiment, etc.).
- Établissement d'une méthodologie de sélection des descripteurs pertinents et calcul d'un classifieur de mouvement à partir d'une base de données couvrant des sujets et des environnements différents.
- Mise en place d'un processus de mise à jour de position par détection de points d'intérêt couvrant l'indoor et l'outdoor.

I.4 Organisation du mémoire

Le *chapitre II* s'intéresse aux méthodes de navigation inertielle ou GNSS. La technologie des capteurs usuellement utilisés en navigation inertielle (Accéléromètre, Gyromètre, Magnétomètre) et les principales erreurs d'une centrale inertielle et magnétique sont présentées à la *section II.1*. Ensuite,

la **section II.2** explique l'approche PDR avec les différentes techniques existantes de détection de pas, d'estimation de longueur de pas ainsi que le principe du calcul d'attitude. Enfin, la **section II.3** présente les mesures GNSS et les principales méthodes de calcul de position à partir de ces mesures.

Le **chapitre III** traite de la carte. La **section III.1** expose les différents contenus cartographiques utiles à la navigation des piétons et les différents formats de cartes existants, la **section III.2** s'intéresse aux transformations existantes de la carte pour lui donner une forme exploitable en navigation, et la **section III.3** présente une transformation innovante de la carte afin de rendre possibles des calibrations du modèle PDR dans les espaces non contraints par les obstacles.

Le **chapitre IV** est dédié à la liaison entre la carte et la signature de mouvement. La **section IV.1** fait un état de l'art en matière d'exploitation de la carte pour la rendre plus informative en termes de localisation à travers des techniques de reconnaissance, la **section IV.2** fait un focus sur le besoin et les défis de la reconnaissance de l'indoor et de l'outdoor, la **section IV.3** présente les algorithmes de classification et de sélection des descripteurs adoptés dans cette thèse pour la reconnaissance de mouvement, et la **section IV.4** explique la méthodologie mise en œuvre pour aboutir à un processus de détection de points d'intérêt et de mise à jour de position par reconnaissance automatique sur le signal.

Le **chapitre V** s'intéresse à la fusion des capteurs avec la carte pour le calcul de position finale. La **section V.1** reprend les bases théoriques du filtrage Bayésien, la **section V.2** fait un état de l'art sur les choix de filtres et de réseaux de navigation adoptés pour améliorer le calcul de position par approche PDR, et la **section V.3** présente un nouveau filtre particulière aidé par un graphe de navigation et par un processus de détection de points d'intérêt dans une approche PDR.

Le **chapitre VI** est consacré à l'évaluation qualitative et numérique des résultats obtenus. La **section VI.1** analyse les performances obtenues pour la reconnaissance de mouvement et la **section VI.2** évalue les résultats de localisation selon plusieurs scénarios d'acquisition.

Chapitre II

II. NAVIGATION AUTONOME GRACE AUX MESURES INERTIELLES OU GNSS	16
II.1 Les capteurs MEMS	16
II.1.1 Technologie MEMS et capteurs inertiels et magnétiques embarqués	16
II.1.2 Modélisation des erreurs d'une centrale IMMU	18
II.1.3 Analyse de la variance d'Allan	19
II.2 Calcul de position par méthode de navigation à l'estime (PDR)	21
II.2.1 Détection de pas	21
II.2.2 Estimation de la longueur de pas	22
II.2.3 Calcul d'attitude de l'IMMU	23
II.3 Données GNSS	27
II.3.1 Mesures	27
II.3.2 Aides GNSS pour la navigation dans les milieux masqués	30
II.3.3 Calcul de position GNSS	30

II. Navigation autonome grâce aux mesures inertielles ou GNSS

Les capteurs utilisés dans le cadre de cette recherche sont assemblés au sein d'une centrale inertielle et magnétique (Inertial and Magnetic Measurement Unit désignée par l'acronyme IMMU). Elle comprend deux capteurs inertiels, à savoir un accéléromètre et un gyromètre, mais également un baromètre et un magnétomètre. Ces capteurs permettent de calculer la position du piéton de manière récursive à partir d'une position initiale connue.

Quel que soit le dispositif auquel l'IMMU est intégrée (smartphone, tablette, smartwatch), cette recherche est menée pour des capteurs de gamme « consommateur » [1]. En revanche, les résultats sont sensibles à la qualité d'extraction des mesures (fréquence d'échantillonnage, stabilité de la fréquence, synchronisation temporelle des données, etc.).

Ce chapitre s'articule comme suivant : La partie II.1 a pour but de présenter brièvement la technologie des capteurs MEMS, leurs principes, ainsi que les différentes erreurs des mesures qu'ils délivrent. La partie II.2 présente le calcul de position par approche PDR. La partie II.3 présente la donnée GNSS en tant que mesure mais aussi en tant que position.

II.1 Les capteurs MEMS

II.1.1 Technologie MEMS et capteurs inertiels et magnétiques embarqués

La terminologie MEMS (Micro Electro Mechanical Systems) a vu le jour grâce au Professeur R. Howe à la fin des années 1980 [4]. Elle décrit les processus de micro-fabrication impliquant des composants aux dimensions inférieures à $100\ \mu\text{m}$ [4] ainsi que l'intégration conjointe de principes mécaniques et électroniques [5].

II.1.1.1 Accéléromètres MEMS

Un accéléromètre mesure la force spécifique subie par l'IMMU suivant son axe de mesure. La force spécifique correspond à la résultante des forces non gravitationnelles appliquées par unité de masse sur le support de l'IMMU [6]. Cela signifie que l'accélération due à la gravité n'est pas mesurée par un accéléromètre, donc la force spécifique d'un corps en chute libre serait nulle. En revanche, pourvu que l'axe de mesure soit parfaitement à la verticale, un accéléromètre mesurera l'effet de toute force s'opposant à la gravité afin de le retenir de tomber.

Le principe mécanique d'un accéléromètre revient au déplacement uni-axial d'une masse retenue par deux ressorts (Figure 3). A chaque fois que le support de l'accéléromètre subit une accélération selon l'axe de mesure, la masse se déplace du fait de la compression d'un ressort et de l'étirement de l'autre. Ce déplacement est généralement mesuré par des capteurs capacitifs [7]. La Figure 4 montre un zoom microscopique de la structure d'un accéléromètre MEMS, tandis que la Figure 5 en donne une vue globale.

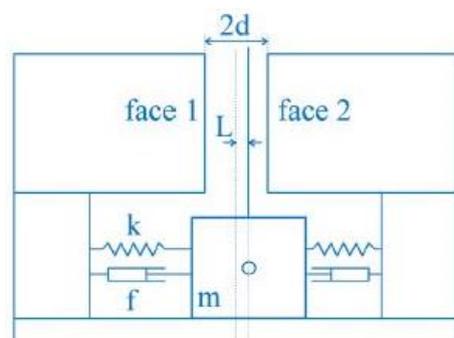


Figure 3: Schéma simplifié d'un accéléromètre. Ce dernier est modélisé par une masse m suspendue entre deux ressorts rigidement liés à la masse m et aux faces 1 et 2. Ils ont une raideur k et un coefficient de frottement f . Le déplacement L résultant du mouvement du support de l'accéléromètre est mesuré grâce à des capteurs capacitifs. La valeur du déplacement L est proportionnelle à l'accélération que subit le support suivant son axe de mesure. Cette mesure correspond à la force spécifique par unité de masse de l'accéléromètre car elle n'intègre pas les effets

gravitationnels [7].

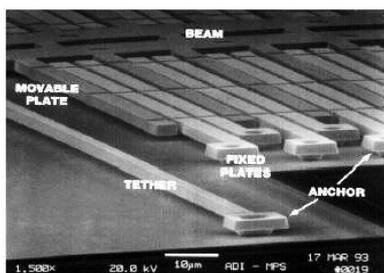


Figure 4: Vue microscopique d'un accéléromètre MEMS. La masse en suspension correspond à la poutre centrale 'beam'. Les lamelles blanches 'Fixed plates' correspondent aux différentes faces de la Figure 3. Ils servent pour la partie électronique permettant de mesurer le déplacement de la masse. Elles sont fixées au support par des 'anchors'. La suspension élastique ou ressort est assurée par les 'tethers' à gauche de l'image. [7]

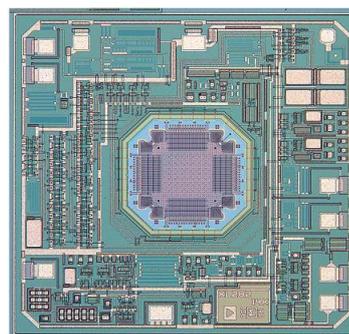


Figure 5: Vue globale d'un accéléromètre MEMS. Le capteur à proprement dit correspond à la partie centrale de l'image où l'on voit la masse centrale, le système de condensateurs et les suspensions sur les bords. [7]

II.1.1.2 Gyromètres MEMS

Un gyromètre MEMS mesure l'accélération de Coriolis d'un élément en vibration lorsqu'il subit un mouvement de rotation [1]. Ce phénomène doit son nom à *Gustave Gaspard de Coriolis* (1792 – 1843) et correspond à l'accélération dans un repère inertiel d'un corps en rotation par rapport à un référentiel Galiléen.

De même que pour un accéléromètre, un gyromètre MEMS peut être modélisé par un élément en suspension (cet élément pouvant être discret tel qu'une masse (ou plusieurs), ou continu tel qu'une corde) à deux degrés de libertés [8] définis par deux axes perpendiculaires liés au repère du gyromètre (Figure 6). La masse oscille suivant l'axe x dit 'Drive-axis' à une amplitude fixe. Cela définit un mode de vibration 'primaire' [8]. Lorsque le gyromètre subit une rotation selon l'axe z , cela entraîne un mode de vibration 'secondaire' résultant du couplage des deux mouvements liés à la vibration propre de la masse et au mouvement de rotation provoqué de l'extérieur. Une oscillation selon l'axe y est alors engendrée et son amplitude est mesurée par le gyromètre. Cette amplitude est proportionnelle à la vitesse de rotation de la masse [1].

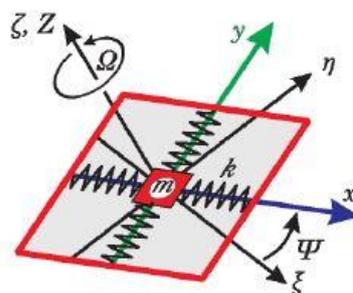


Figure 6: Principe de fonctionnement d'un gyromètre MEMS à une masse vibrante. [9]

Une IMMU comprend en général 3 accéléromètres et 3 gyromètres uni-axiaux afin de fournir des mesures dans l'espace 3D. Ils sont disposés de façon à former deux bases orthogonales de \mathbb{R}^3 dont les axes sont alignés.

II.1.1.3 Magnétomètre

Comme son nom l'indique, un magnétomètre mesure le champ magnétique. Son utilisation dans le cadre de la navigation repose sur l'hypothèse que le champ magnétique mesuré est terrestre, c'est-à-dire qu'il permet d'estimer une orientation par rapport au Nord magnétique [10], laquelle est convertie en direction par rapport au Nord géographique. Etant donné la variété des technologies de fabrication de magnétomètres MEMS, nous nous limiterons à l'exploitation du champ magnétique en navigation

PDR sans s'attarder sur sa technologie en tant que telle. Cependant, il est à noter qu'il est commun, tout comme pour les accéléromètres et gyromètres, de réunir trois magnétomètres uni-axiaux de manière à ce qu'ils forment une base orthogonale de l'espace 3D dont les axes coïncident avec les axes des accéléromètres et gyromètres.

II.1.2 Modélisation des erreurs d'une centrale IMMU

II.1.2.1 Facteur d'échelle

Le facteur d'échelle traduit l'écart entre la valeur effectivement mesurée par le capteur et la valeur délivrée en sortie du processeur (Figure 7) [1]. Cette erreur est modélisée de la même manière pour les capteurs inertiels et pour le magnétomètre.

Dans le cas d'un capteur tri-axes, chaque capteur uniaxe peut présenter son propre facteur d'échelle supposé constant [10]. Globalement, cette erreur est représentée par une matrice diagonale comprenant un facteur d'échelle par axe [1], [10] :

$$S = \text{diag}(s_x, s_y, s_z) \quad \text{E. 1}$$

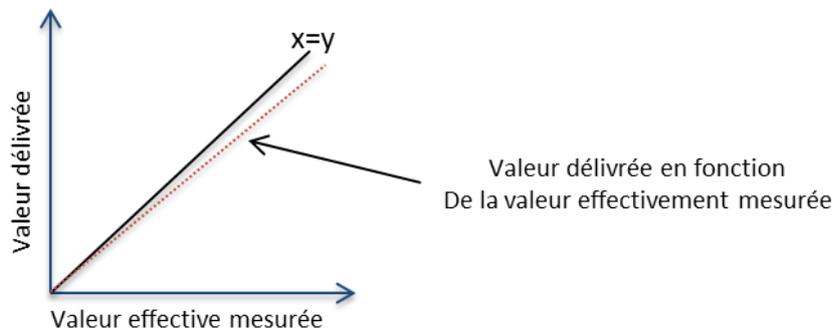


Figure 7: Inspirée de [1], Section : 'Error Characteristics'

II.1.2.2 Erreurs de couplage

Les axes des capteurs sont censés être alignés avec les axes de l'IMMU et former une base orthogonale de \mathbb{R}^3 . Cela suppose une fabrication parfaite, ce qui n'est pas le cas. Il en résulte un couplage au niveau de la mesure : chaque capteur uniaxe fournira une mesure dont la composante principale est suivant son axe IMMU correspondant, mais qui a aussi une composante suivant l'axe de l'IMMU qui lui est orthogonal. Cette erreur est modélisée de la même manière pour tous les capteurs par une matrice à diagonale nulle, comprenant l'erreur de couplage induite pour chaque couple d'axes de l'IMMU :

$$C = \begin{pmatrix} 0 & a_{xy} & a_{xz} \\ a_{yx} & 0 & a_{yz} \\ a_{zx} & a_{zy} & 0 \end{pmatrix} \quad \text{E. 2}$$

II.1.2.3 Biais

De manière générale, un biais correspond à la mesure d'un capteur en absence de signal. Pour les accéléromètres et gyromètres, ce dernier a une composante constante pour chaque mise sous tension dite run-to-run bias, et une composante dite in-run bias ou bias-instability [1] qui varie dans le temps à la suite d'une même mise sous tension. Cette dernière représente approximativement 10% du biais constant [1]. Le biais total est donc modélisé par la somme des deux biais :

$$b = b_{\text{run-to-run}} + b_{\text{in-run}} \quad \text{E. 3}$$

Les instabilités du biais peuvent être estimées pour le gyromètre et l'accéléromètre grâce à la variance d'Allan (partie II.1.3). Le magnétomètre a également un biais mais ce dernier peut être estimé grâce à une calibration en début d'acquisition [11].

II.1.2.4 Bruits électro-mécaniques

Des bruits d'origine mécanique ou électrique viennent s'ajouter aux différents bruits cités précédemment. Ils sont généralement modélisés par des bruits blancs :

$$\boldsymbol{\omega} = (\boldsymbol{\omega}_x, \boldsymbol{\omega}_y, \boldsymbol{\omega}_z) \quad \text{E. 4}$$

II.1.2.5 Champ magnétique induit par les composants du système

L'IMMU est constituée de matériaux ferromagnétiques pouvant interagir avec des champs divers et devenir eux-mêmes des sources de champ magnétique. Une distinction est faite entre les matériaux ferromagnétiques doux et durs [10]. Les premiers peuvent interagir avec des champs externes et produire un champ magnétique. L'erreur liée à ce phénomène est modélisée par la matrice :

$$A_{Mag} = (a_{ij})_{i,j \in \{1,3\}^2}$$

Les ferromagnétiques durs quant à eux génèrent un champ magnétique permanent. La valeur de champ qu'ils induisent est modélisée par un biais :

$$\boldsymbol{b} = [b_x, b_y, b_z] \quad \text{E. 5}$$

II.1.3 Analyse de la variance d'Allan

Au vu de ces imperfections, et par considération des approches de navigation inertielle où les bruits des capteurs peuvent être intégrés, certaines erreurs devront être caractérisées et quantifiées. Pour ce faire, une analyse de la variance d'Allan est menée sur des signaux recueillis sur plusieurs heures.

II.1.3.1 Principe d'analyse de la variance d'Allan

Une approche stochastique usuelle pour caractériser le bruit d'un signal consiste à étudier sa fonction d'autocorrélation. Lorsqu'il s'agit d'un signal stationnaire, la fonction d'autocorrélation constitue la conjuguée de la densité spectrale de puissance du signal par transformée de Fourier. Donc calculer l'un ou l'autre revient au même, à savoir étudier l'aspect stochastique du signal. L'inconvénient d'une telle approche est une longue durée d'acquisition nécessaire ainsi qu'un coût de calcul important [12].

Il se trouve que la variance d'Allan, en plus d'être liée à la densité spectrale de puissance par l'équation E. 6, est plus simple à calculer et à interpréter dans le domaine temporel:

$$\sigma^2(T) = 4 \int_0^{\infty} \Psi_S(f) \cdot \frac{\sin^4(\pi f T)}{(\pi f T)^2} \cdot df \quad \text{E. 6}$$

Où Ψ_S est la densité spectrale du signal S , T une variable temporelle et f une variable fréquentielle.

Un calcul de la variance d'Allan a donc pour objectif de remonter à une forme donnée de la densité spectrale de puissance au moyen de l'équation E. 6, ce que la Table 1 illustre. Cette reconnaissance peut être effectuée aisément sur un graphe en log-log de la variance d'Allan en fonction du temps que nous expliquons dans la partie suivante.

Error Type	PSD (S_{Ω})	AV ($\sigma^2(\tau)$)	Comments
Quantisation Noise	$(2\pi f)^2 Q^2 T_s$	$\frac{3Q^2}{\tau^3}$	Q: Quant. noise coefficient
Random Walk	N^2	$\frac{N^2}{\tau}$	N: Random walk coefficient
Bias Instability	$\left(\frac{B^2}{2\pi}\right) \cdot \frac{1}{f}$ $f \leq f_0$	$\frac{2B^2}{\pi} \left[\frac{\ln 2 - \frac{\sin^2 x}{2x^2} (\sin x + 4x \cos x)}{+Ci(2x) - Ci(4x)} \right]$	B: Bias instability coefficient. $x : \pi f_0 \tau$ Ci: Cosine integration function [9]
Rate random walk	$\left(\frac{K}{2\pi}\right)^2 \frac{1}{f^2}$	$\frac{K^2 \tau}{3}$	K: Rate random walk coefficient
Rate ramp	$\frac{R^2}{(2\pi f)^3}$	$\frac{R^2 \tau^2}{2}$	R: Rate ramp coefficient
Correlated Noise	$\frac{(q_c T_c)^2}{1 + (2\pi f T_c)^2}$	$\frac{(q_c T_c)^2}{\tau}, \tau \gg T_c$ $\frac{q_c^2}{3} \tau, \tau \ll T_c$	q_c : Noise amplitude T_c : Correlation time
Sinusoidal noise	$\frac{\Omega_0^2}{2} [\delta(f - f_0) + \delta(f + f_0)]$	$\Omega_0^2 \left(\frac{\sin^2 \pi f_0 \tau}{\pi f_0 \tau} \right)^2$	Ω_0 : point Amplitude f_0 : point frequency $\delta(x)$: Delta function

Table 1: Densités spectrales de puissance et variances d'Allan associées [12]. La variable τ traduit une largeur temporelle au même titre que T .

II.1.3.2 Calcul de la variance d'Allan

Considérons un signal S qui évolue au cours du temps $t \in \mathbb{R}^+$. Considérons une fenêtre temporelle de largeur $T \in \mathbb{R}^{+*}$ correspondant à $N \in \mathbb{N}^*$ échantillons. Ces N échantillons sur la largeur temporelle T traduisent la fréquence du signal. Choisissons un instant t_k qui est la valeur de la variable t d'indice $k \in \mathbb{N}^*$. Nous nous intéressons à un ensemble de $n \in \mathbb{N}^*$ points ($n < \frac{N}{2}$) appelé cluster et correspondant aux valeurs prises par S entre les instants t_k et $t_{k+1} = t_k + T$. Calculons ensuite la valeur moyenne de ce cluster grâce à la formule suivante :

$$\bar{S}_k(T) = \frac{1}{T} \int_{t_k}^{t_{k+1}} S(t).dt \quad \text{E. 7}$$

Nous pouvons effectuer ce même calcul de manière itérative pour tout $k \in [1, N - 2n]$. Ensuite, pour chaque couple $(k, k + 1)$, calculer la différence :

$$\xi_{k+1,k} = \bar{S}_{k+1}(T) - \bar{S}_k(T) \quad \text{E. 8}$$

Alors la variance d'Allan pour la fenêtre de largeur temporelle T est obtenue par la formule suivante :

$$\sigma^2(T) = \frac{1}{2(N - 2n)} \sum_{k=1}^{N-2n} \xi_{k+1,k}^2 \quad \text{E. 9}$$

II.1.3.3 Application à une marche aléatoire

Nous choisissons l'exemple d'une marche aléatoire. C'est une erreur typique aux approches de navigation inertielle car le bruit blanc du gyromètre, entre autres, est intégré pour le calcul d'orientation. La densité spectrale de puissance d'une marche aléatoire est modélisée par un terme Q^2 , appelé coefficient de marche aléatoire et correspondant à la variance du bruit blanc à l'origine de la marche aléatoire. Par application de l'équation E. 6, on obtient la relation :

$$\sigma^2(T) = \frac{Q^2}{T} \quad \text{E. 10}$$

Ce qui correspond à la 2^{ème} ligne de la Table 1.

Après un passage en log-log, cela équivaut à écrire :

$$\log(\sigma) = -\frac{1}{2} \log(T) - \log(Q) \quad \text{E. 11}$$

Aussi, il est possible de détecter une marche aléatoire sur un signal grâce à la reconnaissance d'une pente de $-1/2$ sur une représentation de $\log(\sigma)$ en fonction de $\log(T)$.

Pour $T = 1$, nous avons $\log(\sigma) = -\log(Q)$, ce qui permet de déduire la valeur du coefficient de la marche aléatoire.

II.2 Calcul de position par méthode de navigation à l'estime (PDR)

L'approche adoptée dans le contexte de la localisation piétonne à l'aide de capteurs tenus dans la main est baptisée PDR pour Pedestrian Dead Reckoning. Elle renvoie aux méthodes qui s'intéressent à la détection de pas [13]. La navigation piétonne basée PDR se fait en deux temps. Il s'agit d'abord de détecter les instants de pas, ensuite d'estimer leurs longueurs. Le calcul d'orientation est quant à lui réalisé de la même manière qu'en navigation inertielle classique par intégration des vitesses angulaires mesurées par les gyromètres. Des méthodes de fusion sont généralement utilisées pour exploiter l'accéléromètre et le magnétomètre dans le calcul d'attitude afin de limiter la dérive engendrée par l'intégration des vitesses angulaires. Dans ce travail, les erreurs d'orientation sont principalement gérées a posteriori du calcul d'attitude par exploitation de la carte. L'algorithme utilisé pour le calcul d'orientation est décrit dans [14]. Cette section explique brièvement le processus de détection de pas dans la partie II.2.1, les modèles d'estimation de longueurs de pas dans II.2.2, ainsi que le principe du calcul d'attitude par exploitation du gyromètre d'un côté, et du magnétomètre et de l'accéléromètre de l'autre dans la partie II.2.3.

II.2.1 Détection de pas

Pour la détection de pas, on exploite la cyclicité de la marche qui se traduit généralement par une périodicité dans le signal d'accélération (Figure 8). Il s'agit alors d'un problème de détection de pics pouvant être résolu par des méthodes de seuillage [15],[16]. La détection de pic peut se faire soit sur l'accélération verticale, comme la force spécifique mesurée par l'accéléromètre est surtout liée à la réaction du sol sur le pied au moment du choc, soit sur la norme de l'accélération, la partie verticale étant difficile à isoler [17]. Une autre difficulté réside dans le choix d'un seuil adapté puisque la détection doit être robuste aux bruits, à la diversité des piétons, des surfaces de sol, etc. [17]. Des méthodes plus élaborées ont été proposées dans la littérature afin de pallier ces difficultés, notamment des approches de seuillage adaptatif [18] ou de seuillage multiple [15]. Toutefois, des cas de sur ou sous-détection peuvent toujours se produire, introduisant une première source d'erreurs liée à la méthode adoptée. Cette erreur est une entité algébrique de l'ordre de la longueur d'un pas (0.65 – 0.85m), cumulable avec d'autres erreurs affectant la distance parcourue par le piéton entre deux instants de pas.

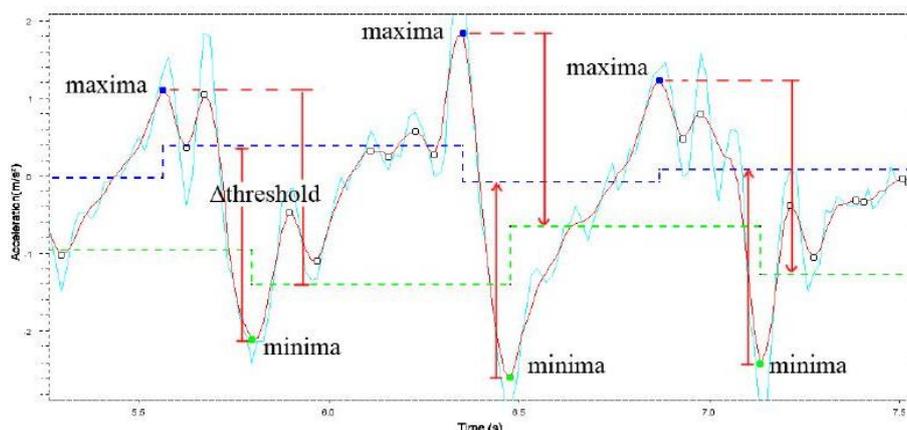


Figure 8: Pattern de l'accélération et détection de pic par seuillage [16]

II.2.2 Estimation de la longueur de pas

Une fois qu'un pas a été détecté, il faut estimer sa longueur. Plusieurs approches ont été proposées dans ce contexte et nous en citons les principales.

II.2.2.1 Estimation empirique

L'approche empirique consiste à supposer une longueur de pas constante par individu [19]. La longueur du pas peut aussi être modulé par la variation d'accélération avec

$$s = \sqrt[4]{A_{\max} - A_{\min}} \cdot C \quad \text{E. 12}$$

$A_{\max/\min}$ sont les extrema de l'accélération verticale sur une fenêtre temporelle correspondant à un pas et C est une constante de calibration estimée par apprentissage.

La distance parcourue est alors déduite en multipliant le nombre de pas par leur longueur moyenne estimée [19],[20],[21]. En réalité, la longueur de pas est liée chez un même individu à la cadence de marche ainsi qu'à la variance de l'accélération [22], [19], [23].

II.2.2.2 Approche biomécanique

L'approche biomécanique repose sur le lien établi entre le déplacement vertical du centre de masse du piéton, la longueur de sa jambe et la longueur de son pas [23]. Le modèle correspondant est un pendule inverse (Figure 9). En effet, la longueur du pas est la somme de deux éléments [24]: le déplacement horizontal (Figure 9 : S1) du centre de masse du piéton pendant que son pied est en contact avec le sol (autour de la « Mid Stance » où le pied est à plat) et son déplacement (Figure 9 : S2) le temps que ses deux pieds soient simultanément en contact avec le sol (« Double Stance »). Ces deux moments correspondent aux extrema de la position verticale du centre de masse du piéton lors d'un cycle de marche normal (i.e. pour un sujet ne présentant pas de pathologie) [25]. Il est établi d'après le modèle du pendule inverse et d'après la définition géométrique d'un pas, qu'étant donné le déplacement vertical du centre de masse du piéton et la longueur de sa jambe, il est possible de calculer la longueur de son pas selon la formule suivante [23], [24]:

$$s = 2 \cdot K \cdot \sqrt{2 \cdot l \cdot h - h^2} \quad \text{E. 13}$$

où s est la longueur de pas, K un facteur de calibration, l la longueur de la jambe et h le déplacement vertical du centre de masse du piéton (variable dans le temps)

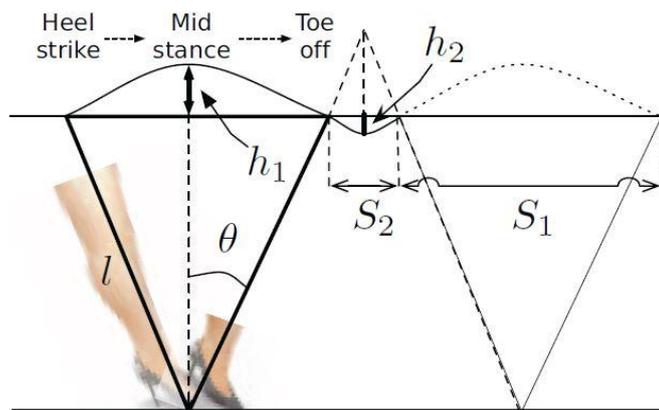


Figure 9: Modélisation de la marche humaine : pendule inverse [24]

Parmi les limites de cette méthode on peut noter une inefficacité lors de l'utilisation de capteurs qui ne sont pas fixés au corps, car il serait difficile de déduire l'accélération du centre de masse du piéton. Une autre limite est liée au fait que l'accélération verticale doit être intégrée pour estimer le déplacement vertical du centre de masse, induisant une double intégration des erreurs de mesures de l'accéléromètre. Et enfin le besoin d'apprentissage pour entraîner le facteur K.

II.2.2.3 Approche paramétrique

Les approches paramétriques permettent d'intégrer, entre autres, la variabilité de la longueur de pas en fonction de la cadence de marche. Plusieurs études ont montré que la longueur de pas varie linéairement en fonction de la fréquence de marche [26]. Il existe ainsi plusieurs variantes pour estimer la longueur de pas, où la fréquence de marche est donnée par la détection de pas et où la longueur de pas est estimée selon une équation linéaire du même genre que [24] :

$$S = K_1 \cdot f_{step} + K_2 \quad \text{E. 14}$$

où K_1 et K_2 sont deux paramètres de calibration et f_{step} la fréquence de marche.

II.2.2.4 Modèle adopté

Le modèle adopté dans le cadre de cette recherche permet de combiner les deux approches paramétrique et biomécanique. Il prend comme paramètres la fréquence de marche (f), estimée indépendamment du processus de détection de pas [27], ainsi que la taille de l'individu (h), compte tenu de sa corrélation avec la longueur de la jambe utilisée dans les approches biomécaniques. La longueur du pas (s) est alors obtenue par la formule suivante :

$$s = h \cdot (af + b) + c \quad \text{E. 15}$$

où $\{a, b, c\}$ sont trois paramètres dits universels puisqu'ils ont été entraînés et estimés empiriquement pour une population d'individus hétérogène.

II.2.3 Calcul d'attitude de l'IMMU

II.2.3.1 Repères de référence

Les différents capteurs intégrés dans une IMMU fournissent des mesures dans leur propre repère de référence déterminé par les axes de mesures -eux même alignés avec les axes de l'IMMU. Le repère orthogonal rigide lié à l'IMMU est communément appelé repère objet ou repère « body ».

Il est ensuite indispensable de ramener ces mesures dans un repère significatif du point de vue de la navigation terrestre. Cela définit un deuxième repère qui peut être soit une base orthonormée de dimension 3 définie à partir de la géodésie terrestre (Ex. coordonnées géodésiques cartésiennes), soit généralement un repère 2.5 D car la solution de navigation sera superposée à un fond de carte ou SIG 2.5D référencés par des coordonnées planes (Est, Nord) accompagnées d'une information d'altitude ou de hauteur ellipsoïdale (notées respectivement h ou H).

S'impose ensuite le repère de référence lié au référentiel Galiléen où le principe d'inertie est vérifié. Les grandeurs physiques mesurées par les capteurs inertiels, telles que la force de Coriolis ou la force spécifique, n'ont de sens que par rapport à un référentiel Galiléen.

Enfin, selon les modèles dynamiques et cinématiques utilisés, il est plus ou moins aisé de résoudre les équations dans un repère donné. En général le repère « body » est choisi comme repère de résolution.

II.2.3.2 Paramétrage des rotations avec les angles d'Euler

Soient deux bases orthonormées de dimension 3 notées b et n . Les angles d'Euler permettent de décrire l'attitude de la base b par rapport à la base n . Le vecteur d'attitude angulaire de b par rapport à n contient respectivement les angles de tangage, roulis et lacet et s'écrit :

$$\Psi = \begin{pmatrix} \psi \\ \theta \\ \varphi \end{pmatrix} \quad \text{E. 16}$$

Les matrices de rotations pour chaque angle sont respectivement R_ψ , R_θ et R_φ . La matrice de passage de b à n est calculée en multipliant les 3 matrices précédentes, selon l'ordre choisi pour effectuer les rotations. L'ordre choisi dans le cadre de ce travail est le même que celui de Ψ :

$$C_b^n = R_\psi R_\theta R_\varphi \quad \text{E. 17}$$

Ainsi si x^B est un vecteur exprimé dans la base B et $x^{B'}$ est ce même vecteur exprimé dans base B' , alors :

$$x^n = C_b^n x^b \quad \text{E. 18}$$

Dans la suite, estimer l'orientation de l'IMMU par rapport au repère de navigation reviendra à résoudre l'expression de C_b^n , qui est la matrice de passage du repère body (b) au repère de navigation (n).

NB : le calcul d'orientation peut aussi se faire avec des quaternions que nous n'aborderons pas dans cet état de l'art. Les orientations utilisées dans le cadre de ce travail sont cependant bien calculées avec des quaternions, lesquels résolvent des problèmes inhérents aux angles d'Euler tels que le problème du blocage de cardan ou Gimbal lock [28].

II.2.3.3 Calcul d'orientation à partir du gyromètre

Il est théoriquement possible d'estimer l'orientation d'une IMMU en exploitant uniquement les sorties du gyromètre $\hat{\omega}_b^i$.

$$\hat{\omega}_b^i = \omega_b^n + \omega_n^i + b_g + n_b \quad \text{E. 19}$$

où :

- $\hat{\omega}_b^i$ est la mesure du gyromètre, correspondant à la vitesse de rotation de l'IMMU par rapport au repère inertielle,
- ω_b^n est la vitesse de rotation vraie de l'IMMU par rapport au repère de navigation,
- ω_n^i est la vitesse de rotation vraie du repère de navigation par rapport au repère inertielle (cela comprend toute rotation de la Terre dans l'espace). Ce terme peut être négligé pour des applications pédestres où les déplacements sont de petite échelle et donc le repère local de navigation est considéré fixe.
- b_g le biais du gyromètre,
- et n_b est un bruit blanc.

On a donc sous une forme simplifiée

$$\hat{\omega}_b^i \approx \omega_b^n + b_g + n_b \quad \text{E. 20}$$

$$\text{Soit } \Omega_b^i \text{ la matrice antisymétrique de } \hat{\omega}_b^i = \begin{pmatrix} \omega_1 \\ \omega_2 \\ \omega_3 \end{pmatrix} : \quad \Omega_b^i = \begin{pmatrix} 0 & -\omega_3 & \omega_2 \\ \omega_3 & 0 & -\omega_1 \\ -\omega_2 & \omega_1 & 0 \end{pmatrix}$$

Il a été démontré que :

$$\dot{C}_b^n = C_b^n \Omega_b^n \quad \text{E. 21}$$

où \dot{C}_b^n est la dérivée de C_b^n .

En faisant l'hypothèse qu'on prend un intervalle de temps Δt assez petit, ce qui est induit de faibles variations angulaires et donc une faible vitesse de rotation $\hat{\omega}_b^i$ estimée par le gyromètre, il est possible de mettre à jour le terme C_b^n dans un processus itératif. Le développement de Taylor-Young permet d'écrire :

$$C_b^n(t + \Delta t) = \sum_{k=1}^{+\infty} \frac{\Delta t^k}{k!} \frac{d^k C_b^n(t)}{dt^k} \quad \text{E. 22}$$

Or d'après l'hypothèse de faible variation de $\hat{\omega}_b^i \approx \hat{\omega}_b^n$ et donc de Ω_b^n : $\frac{d^k C_b^n}{dt^k} = C_b^n (\Omega_b^n)^k$

D'où

$$C_b^n(t + \Delta t) = C_b^n(t) \cdot \sum_{k=1}^{+\infty} \frac{(\Delta t \cdot \Omega_b^n)^k}{k!} \quad \text{E. 23}$$

ce qui revient à écrire :

$$C_b^n(t + \Delta t) = C_b^n(t) \exp[\Delta t \cdot \Omega_b^n(t)] \quad \text{E. 24}$$

En appliquant un développement limité de $\exp[\Delta t \cdot \Omega_b^n(t)]$ au 1er ordre $\exp[\Delta t \cdot \Omega_b^n(t)] = I_{3 \times 3} + \Delta t \cdot \Omega_b^n(t)$, on obtient $C_b^n(t + \Delta t) \approx C_b^n(t) [I_{3 \times 3} + \Delta t \cdot \Omega_b^n(t)]$

Cette dernière approximation donne un aperçu de l'erreur cumulée sur le temps dans le processus itératif de calcul d'orientation de l'IMMU. L'importance de cette accumulation est à l'origine des approches de fusion avec l'accéléromètre et le magnétomètre.

II.2.3.4 Estimation des tangage et roulis par mesure du champ de gravité Terrestre (Accéléromètre)

De même qu'un topographe va procéder à une mise en station afin de niveler son appareil de mesure, un accéléromètre peut être utilisé à cette fin en mesurant le champ de gravité local. En supposant que l'IMMU est immobile et qu'elle a une orientation quelconque dans le repère de navigation, l'accéléromètre va mesurer la force qui s'oppose à la gravité terrestre [6]. Cela définit la verticale du lieu, et donc l'ensemble des plans parallèles au plan (E, N) du repère de navigation. Autrement dit, les angles de tangage (pitch) et de roulis (roll) peuvent être déterminés puisque la transformation entre le plan (x, y) lié à l'IMMU et (E, N) lié au repère de navigation peut être déterminée à une translation près. En effet, connaissant l'expression du vecteur \vec{g}^b qui est l'accélération due à la gravité dans le repère body grâce à la mesure de l'accéléromètre, et dans le repère de navigation \vec{g}^n grâce au modèle de gravité utilisé, il est possible de calculer la matrice de passage entre les deux repères :

$$g^n = C_b^n g^b \quad \text{E. 25}$$

ou bien

$$\vec{g}^b = (C_b^n)^T \vec{g}^n \quad \text{E. 26}$$

où \vec{g}^n est la projection du champ de gravité connu dans le repère de navigation, \vec{g}^b sa projection dans le repère body, et C_b^n la matrice de passage du repère body au repère de navigation.

$$\vec{g}^n = \begin{pmatrix} 0 \\ 0 \\ -g \end{pmatrix}^n \quad \text{E. 27}$$

$$\vec{g}^b = \begin{pmatrix} g_1 \\ g_2 \\ g_3 \end{pmatrix}^b \quad \text{E. 28}$$

En appliquant la formule $\vec{g}^b = (C_b^n)^T \vec{g}^n$ on a :

$$\begin{pmatrix} g_1 \\ g_2 \\ g_3 \end{pmatrix}^b = (C_b^n)^T \begin{pmatrix} 0 \\ 0 \\ -g \end{pmatrix}^n = \begin{pmatrix} g \cdot \sin \theta \\ -g \cos \theta \sin \varphi \\ -g \cos \theta \cos \varphi \end{pmatrix} = -g \cdot \begin{pmatrix} \sin \theta \\ \cos \theta \sin \varphi \\ \cos \theta \cos \varphi \end{pmatrix} \quad \text{E. 29}$$

D'où :

$$\begin{cases} \theta = \arcsin\left(-\frac{g_1}{g}\right) & (1) \\ \varphi = \arctan_2(g_2, g_3) \end{cases} \quad \text{E. 30}$$

Le lacet (yaw) qui définit la rotation selon l'axe vertical permettant d'aligner les axes du repère body au repère de navigation reste à déterminer.

II.2.3.5 Estimation du lacet par mesure du champ magnétique terrestre (Magnétomètre)

De même que pour un accéléromètre mesurant le champ de gravité, le magnétomètre fournit une mesure du champ magnétique (supposé terrestre) dans le repère body noté : m_e^b

Sa transformation dans le repère de navigation est donnée par la matrice d'Euler $C_b^n = R_\psi R_\theta R_\varphi$.

Les matrices de rotation R_ψ , R_θ et R_φ ont été définies dans le paragraphe traitant des angles d'Euler (cf.II.2.3.2). R_θ et R_φ sont connues à partir de l'estimation des valeurs de θ et φ par mesure du champ de gravité.

L'expression du vecteur champ magnétique dans le repère de navigation est m_e^n . Nous pouvons écrire la relation suivante :

$$m_e^n = R_\psi R_\theta R_\varphi \cdot m_e^b \quad \text{E. 31}$$

où

$$m_e^n = \begin{pmatrix} m_1 \\ m_2 \\ m_3 \end{pmatrix} \quad \text{E. 32}$$

La résolution de R_ψ se fait de la manière suivante :

¹ La fonction \arctan_2 (usuellement utilisée dans les logiciels de calcul tels que Matlab) permet de résoudre l'ambiguïté de $-\pi$ sur l'argument angulaire.

Comme toute matrice de rotation a sa transposée comme matrice inverse :

$$R_{\psi}^T . m_e^n = R_{\theta} . R_{\phi} . m_e^b = m^w \quad \text{E. 33}$$

En développant la partie gauche de l'équation :

$$\begin{pmatrix} m_1 \cos \psi + m_2 \sin \psi \\ m_2 \cos \psi - m_1 \sin \psi \end{pmatrix} = \begin{pmatrix} m_1^w \\ m_2^w \end{pmatrix} \Leftrightarrow \begin{pmatrix} m_1 & m_2 \\ -m_2 & m_1 \end{pmatrix} \begin{pmatrix} \sin \psi \\ \cos \psi \end{pmatrix} = \begin{pmatrix} m_1^w \\ m_2^w \end{pmatrix} \quad \text{E. 34}$$

D'où :

$$\begin{pmatrix} \sin \psi \\ \cos \psi \end{pmatrix} = \frac{1}{m_1^2 + m_2^2} \cdot \begin{pmatrix} m_1 & -m_2 \\ m_2 & m_1 \end{pmatrix} \cdot \begin{pmatrix} m_1^w \\ m_2^w \end{pmatrix} \quad \text{E. 35}$$

L'angle ψ est finalement calculé par la formule :

$$\psi = \arctan_2 [m_1 . m_1^w - m_2 . m_2^w, m_2 . m_1^w + m_1 . m_2^w] \quad \text{E. 36}$$

II.2.3.6 Récapitulatif

Nous avons montré qu'il était possible d'exploiter les vitesses angulaires fournies par le gyromètre afin de calculer la matrice d'Euler exprimant l'orientation de l'IMMU par rapport au repère de navigation. Nous en avons constaté une amplification de l'erreur de mesure dans le temps, ce qui implique une dégradation croissante de la qualité des orientations calculées par cette méthode.

Nous avons montré par ailleurs qu'il était possible d'estimer deux angles d'Euler à partir de la mesure du champ de gravité terrestre par un accéléromètre. Cela fournit les deux angles de tangage et de roulis. A partir de cette détermination, il est possible de calculer le lacet à partir de la mesure du champ magnétique terrestre par un magnétomètre.

Pour la mesure du champ de gravité, l'accéléromètre ne mesure cependant pas uniquement le champ de gravité terrestre, mais également toutes les accélérations externes dues aux mouvements de la main. Quant au magnétomètre, il va mesurer un champ magnétique qui a une composante terrestre et une composante qui provient des sources magnétiques introduites par l'Homme. Cela comprend tout matériau ferromagnétique et toute onde électromagnétique. Ces différentes interférences viennent brouiller les champs terrestres considérés avec des champs externes, d'où une mesure faussée, laquelle est utilisée pour le calcul d'orientation.

Enfin, ces calculs sont possibles dans l'hypothèse où l'IMMU est statique. En général cela va servir d'initialisation à un processus itératif où les trois capteurs seront fusionnés. Le calcul d'orientation dans ce travail est réalisé selon l'algorithme décrit dans [14].

II.3 Données GNSS

II.3.1 Mesures

Les satellites GPS (le principe de mesure pouvant être transposé au GNSS de manière plus générale) émettent plusieurs types de signal : trois ondes porteuses, un message de navigation et des codes pseudo-aléatoires parfaitement connus. Les porteuses sont des signaux sinusoïdaux purs dont la fréquence est fixée. Le message de navigation fournit les données d'orbite de chaque satellite : données d'éphémérides, datation des données, correction d'horloge, almanach, corrections ionosphériques, etc. Enfin, les codes pseudo-aléatoires sont des séquences temporelles binaires spécifiques à chaque satellite correspondant à la colonne d'identification des satellites notée PRN (Pseudo Random Noise code) dans les fichiers d'observation. Les porteuses sont exploitées pour la mesure de phase (II.3.1.2). Elles servent aussi à moduler les autres signaux par inversion de phase [29]. La mesure GNSS est réalisée par corrélation du signal reçu du satellite avec sa réplique générée par le récepteur [30]. Les différents types de mesures GNSS sont exposés dans les paragraphes suivants.

II.3.1.1 Mesure de pseudo-distance

La mesure de pseudo-distance est réalisée sur les codes pseudo-aléatoires notés C/A ou P (émis à des fréquences respectivement multiple et sous-multiple de la fréquence de l'horloge atomique embarquée dans le satellite). Elle consiste à mesurer la durée du trajet du code pseudo-aléatoire $\Delta t = t_r^{rec} - t_e^{sat}$, où t_r^{rec} est l'instant de réception du signal par le récepteur GNSS et t_e^{sat} l'instant de son émission par un satellite. Notons que les deux mesures de temps sont fournies par deux horloges différentes : une horloge atomique embarquée dans le satellite, et une horloge quartz dont le récepteur GNSS est équipé. Ces instants sont donc exprimés dans deux bases de temps différentes. Abstraction faite de ce défaut de synchronisation temporelle, il est possible de calculer la distance géométrique entre le satellite et le récepteur grâce à la formule suivante :

$$R_r^s = c \cdot \Delta t_r^s \quad \text{E. 37}$$

où R_r^s est la distance géométrique entre le satellite et le récepteur et c la célérité de la lumière dans le vide. Si ce modèle simplifié était utilisé, les calculs seraient affectés d'erreurs provenant de la désynchronisation des horloges, mais aussi de l'hypothèse faite sur la composition du milieu traversé : du vide. En effet, la traversée de l'atmosphère provoque des modifications de la vitesse de propagation du signal, ce qui n'est pas le cas dans le vide, et entraîne donc des erreurs sur l'estimation de distance. Afin d'améliorer ce modèle, la synchronisation temporelle des horloges satellites avec le temps GPS² est faite par un modèle dont les paramètres sont radiodiffusés, ainsi qu'une approximation des délais atmosphériques. Quant au terme d'horloge récepteur, il est considéré comme une inconnue du problème de localisation, au même titre que la position.

Dès que le signal pénètre dans l'atmosphère terrestre, il subit différentes altérations en fonction des particules rencontrées et de leur densité. Un retard atmosphérique (c'est-à-dire un écart par rapport au temps de trajet si le milieu traversé était réellement vide) est dû à deux facteurs [30] : d'un côté le phénomène de réfraction qui entraîne un allongement géométrique de l'onde (courbure de la trajectoire), et de l'autre une variation de la vitesse de propagation en fonction du milieu, laquelle introduit un allongement dit ionosphérique ou troposphérique relativement aux couches de l'atmosphère. Un modèle plus réaliste de la mesure de pseudo-distance est donné par l'équation suivante :

$$\rho_r^s = R_r^s + c(dt^r - dt^s) + \Delta R^{tropo} + \Delta R^{iono} \quad \text{E. 38}$$

où :

- dt^r et dt^s représentent les écarts entre l'horloge satellite et le temps GPS, puis celui entre l'horloge récepteur et le temps GPS,
- ΔR^{tropo} et ΔR^{iono} sont les allongements troposphérique et ionosphérique.

II.3.1.2 Mesure de phase

La mesure de phase est réalisée directement sur la porteuse. Elle consiste à mesurer le déphasage entre la porteuse au moment de sa réception et sa réplique générée par le récepteur. Cela peut s'écrire selon la simple formule $\Delta\Phi_r^s = \Phi_{reçu} - \Phi_{émis}$ où $\Phi_{reçu}$ et $\Phi_{émis}$ sont les phases de réception et d'émission. Tout le problème consiste à modéliser cette différence de phases qui est fonction de plusieurs éléments : le déphasage total de la porteuse à la mise sous tension du récepteur à t_0 , ainsi que le nombre de cycles écoulés depuis sa mise sous tension jusqu'à un instant t_r , conformément à l'équation suivante :

$$\Delta\Phi_r^s(t_r) = \Delta\phi_r^s(t_r) + N(t_0) + n(t_r) \quad \text{E. 39}$$

où :

² Le temps GPS correspond à une échelle continue de même type que le Temps Atomique International (TAI) basé sur l'atome Césium 133 [30].

- $\Delta\varphi_r^s(t_r)$ est le déphasage modulo 2π à la réception,
- $N(t_0)$ est la partie entière du déphasage total à la mise sous tension du récepteur, appelée ambiguïté entière,
- et $n(t_r)$ le nombre entier de cycles écoulés depuis la mise sous tension du récepteur.

Les observables de cette équation sont $\Delta\varphi_r^s(t_r)$ et $n(t_r)$. La première résulte de la corrélation du signal reçu avec sa réplique, et la deuxième issue d'un compteur de cycles. C'est-à-dire que sur un temps d'observation continu d'un même satellite, l'ambiguïté entière reste la même et le nombre de cycle est incrémenté. L'observable de phase correspond alors à :

$$\Phi(t) = \Delta\varphi(t) + n(t) = \Delta\Phi_r^s - N(t_0) \quad \text{E. 40}$$

où l'ambiguïté entière $N(t_0)$ reste à déterminer. L'équation d'observation pour la mesure de phase s'écrit comme suivant :

$$L_r^s = \lambda\Phi(t) = R_r^s + c(dt^r - dt^s) + \Delta R^{tropo} - \Delta R^{iono} - \lambda N(t_0) \quad \text{E. 41}$$

où λ est la longueur d'onde du signal. Le reste des variables a été introduit antérieurement.

II.3.1.3 Mesure Doppler

Les mesures de pseudo-distance et de phase servent à déterminer la distance entre le satellite et le récepteur, avec une précision accrue pour la mesure de phase. Plusieurs modes d'observations et de traitements peuvent alors être appliqués afin d'estimer la position du récepteur. La mesure Doppler quant à elle sert généralement à déterminer la vitesse de déplacement d'un récepteur GNSS mobile.

L'effet Doppler est communément imagé par les variations de l'impression sonore perçue par un piéton au passage d'une ambulance. En effet, cela traduit une variation de fréquence à la réception qui est due au mouvement de l'ambulance par rapport au piéton. Pour la mesure GNSS, ce décalage fréquentiel s'écrit :

$$\Delta f_r^s = f_r^s - f_e^s = -\frac{f_e^s}{c} \cdot \left[(v^s - v^r)^T \frac{r^s - r^r}{\|r^s - r^r\|} \right] \quad \text{E. 42}$$

où f_r^s est la fréquence de réception de la porteuse par le récepteur, f_e^s est sa fréquence d'émission par le satellite, r^s et r^r sont les vecteurs positions respectifs du satellite et du récepteur dans le repère inertiel, v^s et v^r sont les vitesses respectives du satellite et du récepteur dans le repère inertiel.

- $\frac{r^s - r^r}{\|r^s - r^r\|}$ est le vecteur directeur de la ligne de visibilité entre le satellite et le récepteur,
- et $v_{sr} = (v^s - v^r)^T \frac{r^s - r^r}{\|r^s - r^r\|}$ la vitesse radiale (i.e. projetée suivant ce même vecteur directeur) relative entre le satellite et le récepteur.

Aussi, les inconnues a priori de cette équation sont les vecteurs de position et de vitesse du récepteur, permettant de calculer la vitesse radiale v_{sr} entre le satellite et le récepteur qui est aussi finalement une inconnue. Les données d'orbite du satellite peuvent être calculées à partir des données d'éphémérides. Les observables sont la fréquence de réception et la fréquence d'émission toutes les deux connues du récepteur GNSS. L'équation d'observation peut alors s'écrire :

$$v_{sr} = -c \cdot \frac{\Delta f_r^s}{f_e^s} \quad \text{E. 43}$$

Si la dérive des horloges satellite et récepteur est prise en compte, cette équation devient alors :

$$v_{sr} + c \cdot dt^r - c \cdot dt^s = -c \cdot \frac{\Delta f_r^s}{f_e^s} \quad \text{E. 44}$$

D'où :

$$v_{sr} = -c \cdot \left[\frac{\Delta f_r^s}{f_e^s} + dt^r - dt^s \right] \quad \text{E. 45}$$

II.3.1.4 Imperfections des modèles

Les modèles d'observations présentés permettent de tenir compte des retards atmosphériques et de la désynchronisation des horloges satellite-récepteur qui agissent directement sur la précision des estimées de position et de vitesse du récepteur GNSS. D'autres erreurs restent à intégrer, notamment les multi-trajets qui sont très probables en zones urbaines et qui peuvent engendrer plusieurs mètres d'erreur. Une dernière correction, de faible importance ici, est liée à la relativité des temps observés par le récepteur et par le satellite. Le décalage temporel résultant des effets relativistes peut être modélisé par l'équation suivante :

$$t_{sat}^{sat} = \frac{t_{rec}^{sat}}{\sqrt{1 - \frac{v^2}{c^2}}} \quad \text{E. 46}$$

où t_{sat}^{sat} est l'instant indiqué par l'horloge du satellite dans le référentiel du satellite, t_{rec}^{sat} son observation par le récepteur depuis le repère terrestre, v^2 le carré de la vitesse relative du satellite par rapport au référentiel terrestre, et c^2 le carré de la célérité de la lumière dans le vide.

II.3.2 Aides GNSS pour la navigation dans les milieux masqués

II.3.2.1 GNSS assisté (A-GNSS)

Le GNSS assisté ou A-GNSS repose sur la possibilité d'obtenir les données d'éphémérides et d'almanach via internet ou un réseau de téléphonie mobile. En effet, ces informations sont normalement envoyées dans le message de navigation des satellites et elles ont une validité de 4 heures. Cependant, elles peuvent être lentes à télécharger à cause des limitations de débit ou des ruptures du signal dans les milieux masqués. Ces difficultés se traduisent par une longue durée nécessaire au premier calcul de position par le terminal mobile (Time to First Fix : TTFF). L'A-GNSS permet dans ces cas de raccourcir le temps de téléchargement des données et de prolonger leur validité dans le temps, ce qui réduit le TTFF. Il existe des récepteurs de référence en zones dégagées qui sont connectés à un serveur A-GNSS. Ces derniers envoient le message de navigation au terminal mobile afin de l'assister et d'améliorer son positionnement.

II.3.2.2 GNSS à haute sensibilité (HS-GNSS)

Le signal GNSS est exploitable lorsque sa puissance est au-delà d'un certain seuil. Par exemple, ce dernier est fixé à -160 dBW pour le code pseudo-aléatoire C/A. Dans les canyons urbains ou les milieux intramuros, la puissance du signal est affaiblie, entraînant un rejet de satellites qui peut rendre le calcul de position impossible. Le principe du GNSS à haute sensibilité consiste à exploiter même les signaux de faible puissance pour le calcul de position, en dépit d'une dégradation de sa précision.

II.3.3 Calcul de position GNSS

II.3.3.1 Positionnement en mode absolu (Standalone)

Le calcul d'une position GNSS en mode absolu se fait par multi-latération en calculant l'intersection de plusieurs sphères. Il faut au moins 4 satellites visibles simultanément pour avoir 4

sphères et pouvoir calculer la position du récepteur. La distance de chaque satellite par rapport au récepteur est donnée par la mesure de pseudo-distance. En fonction du signal sur lequel la mesure est faite, le niveau de bruit est équivalent à 1% de la longueur d'onde (Par exemple de 1 à 3m pour une mesure de pseudo-distance sur le code C/A).

Cette méthode est la moins précise car les erreurs atmosphériques et le décalage d'horloge du satellite ne sont pas pris en compte. C'est cependant la méthode généralement utilisée pour calculer la position d'un utilisateur de smartphone. Une équation d'observation correspond à un satellite visible par époque. La durée d'observation d'un satellite par un récepteur statique augmente donc les degrés de liberté du système à résoudre, ce qui revient à améliorer l'ajustement et donc la précision de la position estimée. Dans le cadre de la navigation piétonne, ce calcul est fait en temps réel et les époques d'observations sont très courtes. Le positionnement en mode absolu d'un piéton au moyen de son smartphone est généralement précis à quelques mètres dans les zones dégagées (même si le temps d'observation est court le nombre de satellites visibles est important), mais cette valeur augmente dès que les bâtiments viennent masquer les satellites et introduire des multi-trajets.

II.3.3.2 Positionnement en mode relatif (Differential)

Afin de corriger les décalages d'horloges et les erreurs atmosphériques, un positionnement relatif est adopté. Le principe de cette méthode consiste à exploiter au moins deux récepteurs GNSS dont un est connu en position (par exemple une station permanente du RGP³) afin de calculer la distance qui les sépare (appelée ligne de base). En effet, le décalage d'horloge satellite est éliminé mathématiquement par simple différence⁴ des équations d'observations, tandis que l'hypothèse de corrélation spatiale de l'atmosphère au voisinage des deux récepteurs permet de minimiser les retards atmosphériques. Ils sont en effet supposés égaux pour chacun des récepteurs et donc éliminés par simple différence.

II.3.3.2.1 DGNSS

Le terme DGNSS ou DGPS est utilisé pour désigner le procédé de positionnement relatif (dit aussi différentiel) à l'aide de la mesure de pseudo-distance. Cette méthode peut donner des positions précises jusqu'à 1m.

II.3.3.2.2 Différences de phases

Pour la mesure de phase qui est beaucoup plus précise, il faut résoudre les ambiguïtés entières évoquées à la section II.3.1.2. Le seul moyen pour ce faire est de réaliser des doubles différences⁵ (Figure 10).

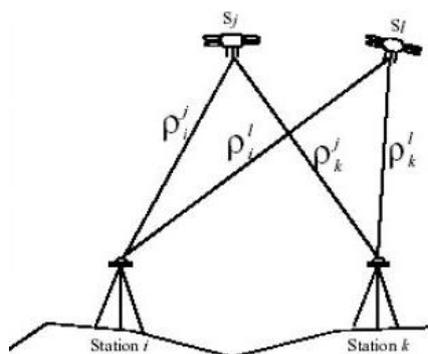


Figure 10: Double différence pour déterminer les ambiguïtés entières [31]

Une fois que les ambiguïtés entières sont résolues, le compteur de cycle permet de résoudre les

³ Réseau GNSS permanent composé de stations GNSS qui enregistrent les données de code et de phases des satellites visibles de manière permanente.

⁴ Une simple différence revient à différencier deux équations d'observations formées par la mesure du signal reçu d'un même satellite par deux récepteurs différents.

⁵ Une double différence est réalisée par différenciation de deux simples différences.

équations d'observation sans ajouter d'inconnue. Cela suppose que la visibilité entre le satellite et le récepteur est continue. En cas de saut de cycle, c'est-à-dire lorsque la visibilité est interrompue à un moment de l'observation, les ambiguïtés doivent être réinitialisées. Un moyen de détecter les sauts de cycles consiste à effectuer des triples différences [31].

La précision de la position estimée par différences de phases est de 1ppm (partie par million : 10^{-6}). Autrement dit, une erreur de 1mm est engendrée pour une ligne de base de 1km. Cependant, les mêmes difficultés liées aux époques d'observations et à la visibilité des satellites dégraderaient la position d'un piéton qui serait en milieu urbain dense. De manière générale, un positionnement relatif au moyen d'un smartphone dans les zones dégagées peut assurer une précision métrique (~2-3m) voire sub-métrique.

Chapitre III

III. MODELES CARTOGRAPHIQUES POUR LA LOCALISATION	34
III.1 Contenu et formats natifs des cartes (Vecteur, Raster)	34
III.1.1 Eléments de la carte significatifs du point de vue des déplacements piétons	34
III.1.2 Différents formats de la carte	38
III.2 Réseaux de navigation	42
III.2.1 Graphe de navigation	42
III.2.2 Mesh de navigation	43
III.2.3 Bilan sur l'utilisation de mesh et de graphes de navigation	44
III.3 Nouveau graphe dans les espaces non-contraints par les obstacles	45
III.3.1 Difficultés de modélisation des espaces non-contraints par les obstacles	45
III.3.2 Adaptation de la notion de portail pour la construction du graphe	45
III.3.3 Génération d'un graphe basé sur les portails	46

III. Modèles cartographiques pour la localisation

Ce chapitre s'intéresse à la modélisation de la carte pour qu'elle soit exploitable dans le processus de calibration PDR. La section III.1 s'intéresse aux informations cartographiques utiles à la navigation des piétons, tout en faisant un état de l'art des formats natifs de la carte. La section III.2 fait un état de l'art des différentes transformations possibles de la carte pour générer un réseau de navigation permettant de calibrer les modèles PDR, tandis que la partie III.3 présente un nouveau graphe dans les espaces non contraint par les obstacles.

III.1 Contenu et formats natifs des cartes (Vecteur, Raster)

III.1.1 Eléments de la carte significatifs du point de vue des déplacements piétons

III.1.1.1 L'accessibilité

Les piétons interagissent avec l'environnement pour planifier leurs trajets. Parmi ces interactions, il y a celle de l'adaptation à la morphologie de l'espace pour l'évitement des obstacles, ce qui revient à évaluer le critère d'accessibilité. Or ce dernier n'est pas le même selon les capacités cognitives et motrices de chaque individu (Figure 11). Par conséquent, la notion d'obstacle doit être considérée de manière relative à son profil de mobilité. Pour cela, les caractéristiques physiques de l'utilisateur devraient être prises en compte pour juger de ses capacités à naviguer dans un espace donné, et surtout pour transiter entre plusieurs régions de l'espace qui lui sont accessibles. Par exemple, selon la taille de l'individu, un trou peut être dépassé ou non, une marche montée ou non, etc. [32]. Nous reprenons à titre d'illustration les travaux réalisés dans le cadre du projet HAPPYHAND2 dans la Table 2 détaillant l'impact de plusieurs obstacles potentiels au vu de profils de mobilités variés.

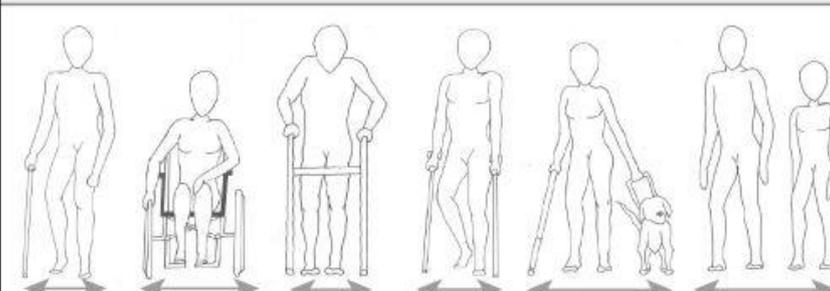
Aide au déplacement	Canne, béquille seule	Fauteuil	Rolator, déambulateur	Béquilles	Canne blanche et chien	Personne accompagnante
Largeur (en cm)	70 *	65-75 *	80 *	90 *	110 *	120 **
Illustrations (non exhaustives)						
Sources : * Grobois, 2010 ; ** http://www.anlh.be/accessvoirie/acc07.htm Auteur : Victor N., 2015						

Figure 11: Largeur accessible par profil de mobilité [33]

Situation ⇒	Fauteuil Roulant	Cécité	Malvoyance*	Surdité**	Mal-audition**	Femme enceinte	Bagages Poussette	Aide- technique à la marche, Marche difficile
Obstacles ↓								
Sols								
Meuble	2	2	2	0	0	1	1	2
Glissant	2	3	3	0	0	2	2	2
Trous	3	3	3	0	0	2	2	3
Fentes	2	3	2	0	0	1	1	2
Largeur								
Etroitesse (<1,20m)	3	2	2	0	0	0	1	1
Elévations								
Trottoir	3	2	1	0	0	1	1	2
Ressaut	2	1	1	0	0	0	0	1
Pentes non normées	3	1	1	0	0	1	1	2
Dévers (>2%)	3	1	1	0	0	1	1	2
Escalier	3	1	1	0	0	2	3	3
Mobiliers urbains								
Poteaux	2	2	1	0	0	0	0	0
Panneaux	2	2	1	0	0	0	0	0
Barrière	2	2	1	0	0	0	0	0
Absence bande d'éveil de vigilance (BEV)	2	3	2	0	0	0	0	0
Objets en saillie	2	3	3	0	0	1	1	1
Bancs & banquettes	0	2	1	0	0	0	2	1
Assises perchées	1	3	2	0	0	0	1	1
Poubelles fixes	2	1	1	0	0	0	1	1
Poubelles mobiles	3	2	2	0	0	1	2	2
Grilles (mailles >2cm)	2	3	2	0	0	1	1	2
Jardinière/Bac	2	2	1	0	0	0	1	1

Table 2: Tableau d'impact de différents obstacles relativement à différents profils de mobilité

Une fois que le relativisme du critère d'accessibilité est établi, il devient évident que la carte qui assiste le piéton est en effet un SIG⁶ combinant de l'information géographique et de la donnée sémantique. Cette dernière est plus que nécessaire afin de rendre compte des caractéristiques du terrain

⁶ Système d'Information Géographique

servant à l'évaluation du critère d'accessibilité. Toutefois, certains obstacles acquièrent un caractère absolu tels que les murs et façades de bâtiments, les éléments du mobilier tels que les bancs, les arbres, les éléments de décoration, etc. Nous dirons que ce sont des obstacles à échelle humaine.

III.1.1.2 La sécurité

Un espace accessible n'est pas nécessairement sécurisant pour l'utilisateur. A titre d'exemple, il y a moins de risques à emprunter un passage piéton pour traverser, même si la chaussée reste accessible. Cela est de première importance pour les personnes mal voyantes [34], de même que l'évitement des croisements de routes et des chaussées mixtes où les aléas sont plus présents [35]. Pourquoi ne pas considérer les espaces dangereux comme inaccessibles? Rappelons d'abord que le rôle de la carte a deux facettes : La première consiste à donner un sens physique à la position de l'utilisateur, et donc à modéliser toutes les positions possibles, techniquement navigables, malgré une sécurité affaiblie. La seconde consiste à participer à la planification du trajet; auquel cas la carte joue un rôle plus déterminant et vient limiter la liberté de l'utilisateur à travers une restriction de l'espace navigable dans le but de l'assister. Afin de répondre à ces deux rôles, la carte doit donc contenir l'ensemble de l'espace accessible par tous, y compris les espaces dont le niveau de sécurité est jugé bas. Cependant, elle doit contenir également les données nécessaires à l'évaluation de leur niveau de sécurité, ce qui requiert une cartographie fine, ou du moins une sémantique assez riche pour couvrir l'ensemble de ces informations. Nous citons à ce propos les travaux de Nadja Victor sur une typologie non hiérarchisée⁷ des voies pédestres urbaines [33]. C'est un travail inspiré du cadre législatif Européen relatif à la route. Trois types de voies (Figure 14) y sont différenciés. Il s'agit des voies dédiées (Inaccessibles aux moyens de transport), des voies en site propre (i.e. fondamentalement dédiées aux véhicules) qui sont contiguës avec des voies réservées aux piétons tels que les passages piétons, et enfin les chaussées mixtes (appelées voies de rencontre). La liste exhaustive des éléments appartenant à chaque type de voie est tout aussi intéressante dans ce travail. En effet, avec une typologie aussi fine, un calcul d'itinéraire adapté peut être proposé à l'utilisateur de manière à lui assurer le plus haut niveau de sécurité.

III.1.1.3 L'optimalité

Si la sécurité est un impératif que la carte doit considérer, il faut aussi tenir compte du confort de l'utilisateur pour une navigation optimale. Ici, la notion de confort peut être comprise en contraste avec une fatigue physique ou un stress psychologique liés au profil de mobilité de l'utilisateur. La prise en compte de ces deux facteurs sous-tend un processus d'optimisation avec une métrique et un critère déterminés, éventuellement sous un ensemble de contraintes qui sont fondamentalement données par les deux premiers prérequis d'accessibilité et de sécurité. Chaque processus d'optimisation est compatible avec un formalisme donné de l'espace navigable [32]. Cela est notamment déterminant pour le choix de la métrique qui permet d'évaluer l'optimalité d'un trajet. Par exemple, la métrique usuellement utilisée lorsque l'espace navigable est donné par un graphe (III.2.1) est la distance Euclidienne. Lorsque l'espace navigable est modélisé par une grille, il convient d'adopter la distance de Manhattan avec les algorithmes Dijkstra ou A* [36].

La plupart des algorithmes de planification d'itinéraires cherchent à minimiser la distance entre un point de départ et un point d'arrivée, ce qui traduit une minimisation du temps de parcours à une vitesse donnée. Les seules données nécessaires dans ce cas sont les positions de départ et d'arrivée de l'utilisateur. Cependant, des études stipulent que la fatigue peut être plus importante pour des distances ou des temps de parcours plus courts, par exemple lorsque le trajet est marqué par le relief [37]. Le critère d'optimisation sous-jacent est alors l'énergie dépensée et non plus le temps nécessaire pour effectuer le trajet. Dans cette optique, l'étude [37] a introduit les notions de charges (Burden) physique et psychologique auxquelles l'utilisateur est sujet ainsi qu'un moyen de les quantifier. La charge psychologique est évaluée grâce à la méthode AHP (Analytic Hierarchy Process) [38] qui permet de dériver des ratios à partir de comparatifs entre couples de variables discrètes et continues. La charge physique est quant à elle liée à la topographie du terrain ainsi qu'à la distance parcourue. Cela permet

⁷ Nous parlons de typologie non hiérarchisée car elle peut faire l'objet d'une hiérarchisation relative aux contraintes de sécurité propres à chaque utilisateur

notamment de distinguer une accessibilité impossible d'une accessibilité difficile [37]. En effet, cette étude a surtout proposé une méthode d'optimisation prenant en compte des critères hétérogènes. Nous pensons qu'elle peut être efficacement mise en œuvre pour des données réelles concernant les préférences des piétons selon leurs profils de mobilité. Dans ce cadre, L'étude [34] s'est intéressée aux différents critères importants pour la planification (ou le choix) d'un trajet par les personnes malvoyantes. Sur la Figure 12, des critères ont été repris de l'état de l'art. Ils sont classés dans l'ordre décroissant en fonction de leur importance et sont valides pour des personnes sans difficulté physique ou psychologique particulière. Outre ces critères, pour les personnes malvoyantes, l'évaluation d'un trajet tient compte du nombre de points d'intérêts et de repères qu'il contient. La présence de repères et de signalisations est fort recommandée par les recherches dédiées à la navigation des personnes malvoyantes [39] ou [40] (Figure 13). D'un point de vue plus général, il a été proposé dans [41] de faire participer les utilisateurs en saisissant leurs préférences dans une approche collaborative. Sur la base d'un réseau de navigation déjà existant sous forme de graphe, il s'agit de noter des segments de routes (piétonnes) en fonction des difficultés rencontrées par les utilisateurs. L'efficacité de cette démarche est d'autant plus significative que les personnes ayant le plus d'influence sur une région de l'espace sont celles qui l'empruntent le plus souvent.

Criteria	Rank
Shortest Distance	1
Least Time	2
Fewest Turns	3
Most Scenic/Aesthetic	4
First Noticed	5
Longest Leg First	6
Many Curves	7
Many Turns	8
Different from Previous	9
Shortest Leg First	10

Figure 12: Liste ordonnée des critères impliqués dans le choix d'un trajet [34]

Important types of information - Visually Impaired Persons

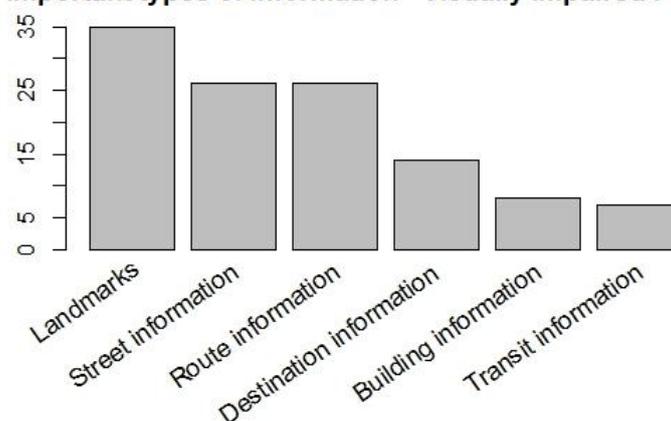


Figure 13: Graphique réalisé à partir des données de l'étude [40] sur les éléments cartographiques importants pour la navigation des personnes malvoyantes.

	Particularités	Types de voies	Illustrations (non exhaustives)
Voie dédiée	<ul style="list-style-type: none"> - Usagers piétons prioritaires sur les autres modes (coprésence parfois autorisée à certains horaires), - Liberté de mouvement sur l'ensemble de l'espace, - Normes d'accessibilité non systématiques, 	Rue piétonne	
		Place	
		Traverse	
		Passerelle	
		Allée	
		Chemin	
		Sentier	

	- Absence de nuisances directes conséquentes à la présence d'infrastructures de transport (insécurité, bruit)	Ascenseur 
		Escalier 
		Pelouse 
Voie en site propre	- Coprésence d'infrastructures de transport, - Espace normé attribué aux usagers piétons, - Normes d'accessibilité quasi systématiques (exception pour traversée informelle)	Trottoir 
		Passage piéton 
		Traversée informelle 
		Accotement 
		Pont 
		Parking 
Voie de rencontre	- Coprésence d'autres modes de transport limités à 20 km/h, - Liberté de mouvement sur l'ensemble de l'espace s'il n'y a pas de gêne pour les véhicules	Chaussée mixte 

Auteur : Victor N., 2015

Figure 14: Typologie des voies piétonnes [33]

III.1.2 Différents formats de la carte

III.1.2.1 Aperçu sur les SIG

Un SIG se définit par deux éléments: Une géométrie et des données attributaires [42]. Les données attributaires forment une base de données qui « cache » l'information associée à chaque objet géométrique. Les premiers SIG ont été obtenus par numérisation de photos aériennes ou d'anciennes cartes papier. Une fois numérisée, une carte peut être enrichie par de l'information sémantique afin de convenir à une analyse spatiale ultérieure. Nous nous pencherons dans le paragraphe traitant des données vectorielles (III.1.2.3) sur les avantages des SIG. Néanmoins, une différence importante par rapport à la carte papier est la possibilité de mise à jour et d'enrichissement dans le temps d'un SIG.

III.1.2.2 Les rasters

La donnée raster est une représentation matricielle de l'espace. Souvent, on parle de couches raster car plusieurs rasters sont superposés afin de représenter différentes informations sur une même zone géographique (par exemple les trois canaux Rouge Vert Bleu pour les images couleur). Une couche raster est modélisée par une matrice de dimension $N \times M$:

$$A = (a_{ij})_{i,j \in \{1,N\} \times \{1,M\}} \quad E. 47$$

Dans cette matrice, chaque terme représente un pixel dont les coordonnées dans l'espace image sont $\{i,j\}$ et la valeur est a_{ij} . Cette valeur est codée en langage binaire. Le pixel a souvent une forme carrée et est caractérisé par sa résolution spatiale (taille correspondante sur le terrain).

Par sa nature, une carte raster est incompatible avec la définition d'un SIG car l'intégralité de l'information est contenue dans la valeur du pixel. De ce fait, elle a comme fonction principale la visualisation. Elle constitue cependant une donnée primitive permettant par la suite de générer des données vectorielles par voie de numérisation ou de reconnaissance automatique. L'exemple le plus

répandu du format raster est la photographie aérienne. Ce format est parfois enrichi de tags⁸ et/ou est superposé avec des données vectorielles telles que les corps de rues, les pistes cyclables ou les accès piétons (Figure 15).



Figure 15: Superposition de photographie aérienne avec des tags et des éléments vectoriels de routes sur Google Maps



Figure 16: Photographie aérienne de l'IGN⁹ [43]

Le passage des coordonnées-image aux coordonnées-terrain est assuré grâce à un processus de géoréférencement. C'est ce qui détermine la précision géométrique d'une carte raster. Le géoréférencement d'une donnée raster consiste à affecter une position géographique à chaque pixel. Pour les prises de vues, cela peut se faire par application d'un modèle physique connaissant les paramètres internes de la caméra (focale, matrice de calibration de la distorsion optique), ainsi que ses paramètres externes (position et orientation dans l'espace). S'il s'agit de donnée numérisée ou que les paramètres de prise de vue ne sont pas connus, il est possible d'exploiter la connaissance a priori que l'on a sur la position sur le terrain d'un ensemble de pixels, alors un simple calcul d'ajustement permettra d'affecter directement une position géographique à chaque pixel. Parfois les deux méthodes sont combinées.

III.1.2.3 Les vecteurs

III.1.2.3.1 Le format vecteur

Une carte vectorielle est un ensemble d'objets géométriques associés à une base de données (BDD). Cette dernière se présente sous la forme d'un tableau appelé table attributaire qui a au moins une colonne. Cette colonne contient une valeur appelée clé primaire propre à chaque objet de la carte. Un objet est par ailleurs caractérisé par une géométrie et des attributs, d'où l'appariement fort entre donnée vectorielle et SIG. La donnée vectorielle peut être organisée en couches/calques (Layers), par exemple une couche « Bâti » et une couche « Routes ». Le format vecteur offre la possibilité de décrire différentes formes géométriques comme des ponctuels pour les arbres et les bancs, des linéaires pour les rues, des surfaciques pour les bâtiments, des courbes pour les cours d'eau ou encore des régions à géométrie complexe pour les zones tampon. Cette souplesse de représentation permet, entre autres, de réaliser des analyses spatiales adaptées aux besoins en combinant information sémantique et information géométrique. Dans ce travail, l'ensemble des données vectorielles seront traitées grâce au logiciel QGIS [44] qui est en libre accès.

III.1.2.3.2 Données vectorielles pour la navigation piétonne-Outdoor

Cette partie traite d'un exemple de carte vectorielle de l'espace extérieur (Outdoor). D'abord conçue pour cartographier l'ensemble des routes dans le monde, elle a ensuite été étendue aux réseaux cyclables et pédestres. Il s'agit de la plateforme OSM¹⁰ qui est une plateforme collaborative en libre accès. Aussi, il est possible pour tout individu lambda de l'enrichir/modifier en manipulant (saisi,

⁸ Donnée sémantique décrivant un endroit ou un objet de l'espace

⁹ Institut national de l'information géographique et forestière

¹⁰ Open Street Map

suppression, modification) des objets vectoriels tels que les bâtiments, les rues ou différents objets du mobilier urbain (Table 3). Le caractère libre de cette donnée et sa démocratisation n'est pas l'unique raison de notre choix de développement sur OSM. Nous pensons que l'approche de cartographie OSM, du fait de sa documentation exhaustive et de son large déploiement, peut être généralisée, et, de sur, nous n'avons pas connaissance d'autres plateformes de cartographie outdoor en libre accès qui soient aussi largement déployées et documentées. Il convient toutefois de rappeler l'existence de contributions privées, à échelles locales, comme c'est le cas pour le projet HappyHand où une cartographie en 3D d'une zone de 300x300 m² a été réalisée.

Les données OSM ne sont pas organisées en couches mais plutôt à l'aide de tags suivant une nomenclature normalisée [45] (Table 3, 2nde colonne). Chaque objet est décrit par un triplet d'informations (resource, property, value), par exemple le triplet (point(x, y); highway; primary) [46]. Ce dernier peut ensuite être enrichi par des propriétés qui viennent affiner sa description. OSM propose dans ce sens un schéma de cartographie à haut niveau de détail dédié aux trottoirs [47]. A titre d'exemple :

- `Highway = Footway`, signifie qu'il s'agit d'une voie piétonne
- `Footway = Sidewalk`, signifie que la voie est un trottoir, et :
- `Sidewalk = left`, signifie qu'il s'agit d'un trottoir gauche

Ensuite, il est possible de fournir davantage de détails sur les trottoirs à l'aide d'attributs qui sont également normalisés:

- `sidewalk:left:width = 3 m`, donne la largeur du trottoir
- `sidewalk:left:kerb = raised`, signifie que la bordure est surélevée
- `sidewalk:both:surface = paving_stones`, donne le surface de revêtement (pavage)

Néanmoins, si le schéma pour une cartographie fine existe dans OSM, les contributions restent libres et d'origines diverses. Par conséquent, le niveau de détails n'est pas spatialement homogène et on peut trouver facilement des objets finement décrits et d'autres qui le sont beaucoup moins. Cette hétérogénéité ne concerne pas seulement le niveau de détail, mais aussi la précision géométrique des différents objets de la carte. En effet, les contributions peuvent provenir directement de traces GNSS, par numérisation de fond de cartes ou par saisie manuelle. Aussi, une caractérisation globale du réseau de navigation OSM, tant en précision qu'en niveau de détail, reste aujourd'hui un problème ouvert et n'a de sens qu'à échelle locale [48].



Figure 17 : Objet polygonal représentant un bâtiment

architect	ArcA3
building	apartments
building:levels	7

Figure 18 : Données attributaires décrivant l'objet « bâtiment »

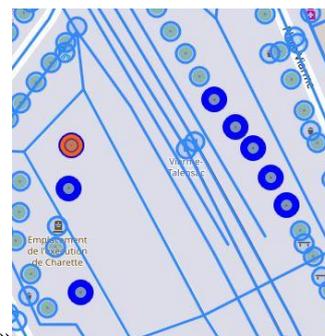


Figure 19 : Objet ponctuel représentant soit un arbre soit un banc

Attributs

amenity	bench
backrest	no
material	concrete
seats	3

Figure 20 : Données attributaires décrivant l'objet ponctuel

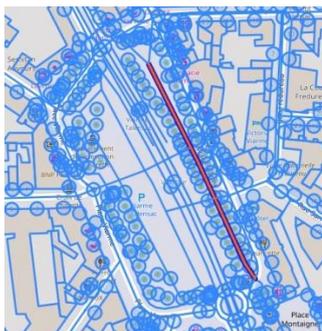


Figure 21 : Objet linéaire décrivant une voie

Attributs

bicycle	designated
highway	footway
lit	yes
motor_vehicle	no
motorcycle	no

Figure 22 : Données attributaires décrivant l'objet linéaire « voie »

Table 3 : Représentation vectorielles d'un bâtiment (a), d'objets ponctuels comme arbres et bancs (b), et de voies (c). La colonne de droit donne les données attributaires de chaque objet conformément à la nomenclature fixée par OSM.

III.1.2.3.3 Données vectorielles pour la navigation piétonne-Indoor

Les plans d'intérieur sont généralement des cartes vectorielles obtenues avec des logiciels de CAO¹¹ (CAD¹²). Dans AutoCAD [49] par exemple, un fichier vecteur au format *dwg*¹³ peut être organisé en calques, lesquels décrivent différents éléments du plan comme les accès, les murs, les cages d'escaliers, les fenêtres, etc. Ces plans ont généralement une précision de l'ordre du centimètre. Un plan architectural de type CAD comprend l'ensemble des informations qui caractérisent un bâtiment en intégrant les aspects géométrique, sémiologique et sémantique. Cet important niveau de détail (Figure 23) requiert alors une simplification afin d'extraire un réseau

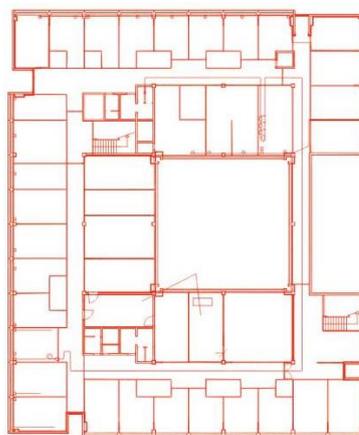


Figure 23: Capture d'un plan CAD

de navigation contenant uniquement l'information utile pour naviguer.

Outre les plans CAD, un système de tags de données vectorielles, tout comme pour les réseaux de circulation automobile, existe pour la cartographie indoor sous OSM. Selon [50], 388 gares SNCF y étaient déjà cartographiées en 2016. Néanmoins, le niveau de détail des plans d'intérieurs sous OSM reste généralement pauvre car les obstacles permanents comme les murs ne figurent pas sur la carte (Figure 24). Pour combler cette lacune, une démarche globale permettant d'intégrer un plan CAD à OSM a été proposée [50], mais elle reste aujourd'hui au stade d'une proposition à mettre en œuvre dans le futur. Ce niveau de détail existe cependant chez Google notamment pour les gares SNCF et les centres commerciaux. Ces plans ont bien entendu un format vectoriel et sont accompagnés d'un système de tags permettant de différencier les éléments du plan (Figure 25). Contrairement à OSM, ces données sont la propriété de Google et il n'est a priori possible de les utiliser que dans un objectif de visualisation, à titre onéreux si l'application visée est payante [51]. Autrement dit, l'accès aux données vectorielles brutes n'est a priori pas possible pour intégrer l'information de la carte au processus de fusion avec les capteurs.



Figure 24: Cartographie intérieure dans OSM



Figure 25: Extrait Google Maps d'une représentation en 2.5D de la Gare Montparnasse. On peut visualiser les tags 'Entrée/Sortie' ainsi que 'Parking handicapé'. À droite, il est possible d'indiquer le numéro d'étage que l'on souhaite visualiser.

III.2 Réseaux de navigation

Les réseaux de navigation sont le résultat de la transformation de la carte pour l'adapter aux besoins de navigation. Nous distinguons deux grandes catégories de réseaux de navigation qui sont les graphes de navigation (III.2.1) et les mesh de navigation (III.2.2).

III.2.1 Graphe de navigation

III.2.1.1 Cartographie indoor

Un graphe est un réseau de navigation constitué de segments connectés via des nœuds. Il y a deux catégories de graphes. Cette distinction est fondée sur la manière dont le graphe est construit. S'il est déterminé par la géométrie spatiale alors il est dit « layout-based ». Si sa construction est fondée sur une autre information, par exemple la configuration des routeurs WIFI dans un bâtiment [52], alors il est dit « layout-independent ». Dans ce travail nous nous intéressons davantage aux graphes dits « layout-based » étant donné l'importance accordée à la configuration géométrique de l'espace. En cartographie indoor, les nœuds correspondent à des endroits prédéfinis tels que les accès (portes, ascenseurs, etc.) ou les intersections de couloirs [53]. Les segments sont les connexions possibles (chemins simplifiés qu'un piéton peut emprunter) entre les nœuds (Figure 26).

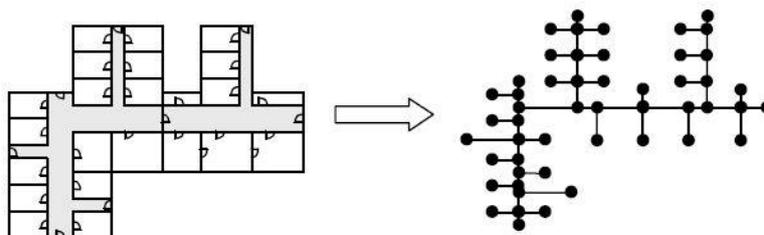


Figure 26: Transformation d'un plan d'intérieur en graphe de navigation [54]

Ce modèle peut être étendu à des représentations en 2.5D (Figure 27) :

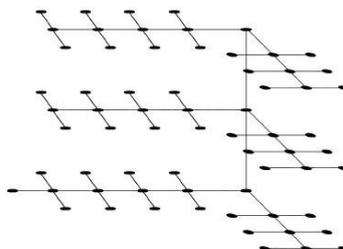


Figure 27: Représentation sous forme de graphe d'un bâtiment en 2.5D [55]

III.2.1.2 Cartographie outdoor

En extérieur, les arcs du graphe correspondent généralement aux trottoirs, aux passages piétons et aux différentes voies accessibles aux piétons (Figure 28).

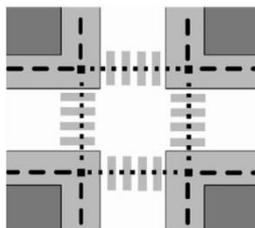


Figure 28 : Trottoirs et passages piétons (pointillés noirs) [56]

La modélisation de l'espace navigable par un graphe de navigation fournit aux algorithmes de fusion deux informations géométriques distinctes. La première est l'orientation des arcs ; la seconde est l'information d'obstacles (murs, mobiliers, etc.) qui permet d'exclure ces derniers de l'espace des solutions. La section V.2 fait un état de l'art sur la manière dont cette information peut être prise en compte pour améliorer le calcul de position.

III.2.2 Mesh de navigation

Un mesh est un maillage permettant de donner une structure géométrique à la carte. Cette structuration permet de générer un réseau de navigation ayant une topologie et donc des règles de franchissement et de transition. L'objectif d'un mesh consiste principalement à planifier un trajet dans des environnements plus ou moins complexes [57], [58] . Diverses méthodes existent pour partitionner l'espace indoor [59]. Le choix peut être porté sur des structures régulières (Figure 29) ou aléatoires (Figure 30).

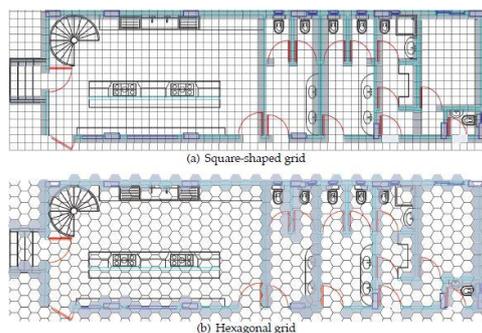


Figure 29 : Maillages réguliers carré et hexagonal [59]

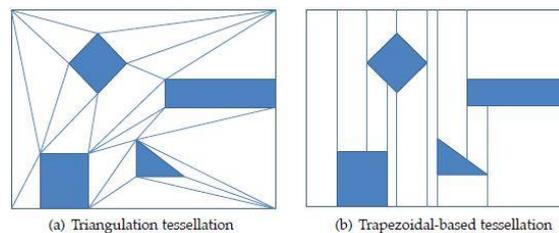


Figure 30 : Maillages irréguliers sous forme de tessellation triangulaire et trapézoïdale [59]

Nous considérons cette représentation comme une approche surfacique car chaque partition de l'espace est une surface en 2 dimensions [57]. Un mesh de navigation ne contient en principe que l'espace accessible par le piéton. Un moyen simple d'éliminer les obstacles consiste à réaliser un seuillage de la pente du terrain pour éliminer les zones inaccessibles, pourvu que cette information soit disponible. Ces méthodes sont donc valables pour des représentations en 3 dimensions telles que le BIM¹⁴. Sinon, la séparation se fait à partir d'une carte vectorielle où les informations attributaires et géométriques permettent de juger de l'accessibilité des espaces. Ces modèles sont par ailleurs inspirés des méthodes de représentation d'espaces virtuels pour la navigation des agents [57], [58], [60], [61]. Chaque partition a un ensemble d'attributs pouvant intervenir dans la planification et le suivi du trajet de l'agent. Un attribut peut par exemple correspondre à une propriété physique telle que la pente ou la surface de revêtement. La Figure 31 montre un exemple de mesh dans un format raster où l'espace navigable est en blanc et les obstacles en noir. Le format raster se rapporte ici à un maillage carré dont l'unité est le pixel. La Figure 32 montre un mesh de navigation vectoriel où les escaliers sont reconnus comme navigables, tout en étant nuancés des étages. En effet, un mesh de navigation permet de caractériser chaque partition de l'espace par rapport à un mode de navigation donné. Par exemple, le modèle de déplacement du piéton varie selon qu'il est en train de marcher sur un terrain plat ou de monter les escaliers, et ceci est de première importance pour la mise en place d'une méthode de localisation adéquate.

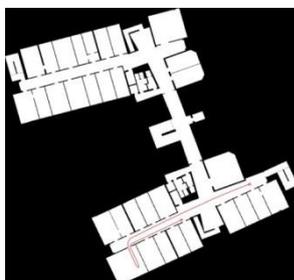


Figure 31: Exemple de carte Bitmap (raster) où les pixels navigables sont blancs et les autres noirs [62]

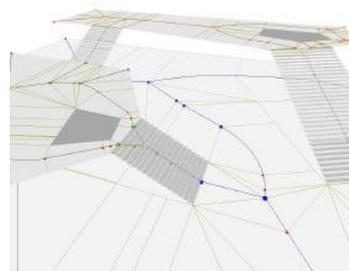


Figure 32 : Exemple de Mesh de navigation [63]

Une fois que le mesh de navigation est créé, le calcul d'itinéraire permet de générer le même type d'information qu'un graphe de navigation, à savoir une mesure d'orientation ainsi que l'évitement d'obstacles. Néanmoins, cette approche suppose une connaissance a priori du trajet, ce qui n'est pas toujours le cas.

III.2.3 Bilan sur l'utilisation de mesh et de graphes de navigation

La représentation sous forme de mesh est intéressante pour la planification de trajets indoor. C'est ce qui est adopté pour la navigation des agents virtuels se déplaçant d'un point A à un point B. Cependant, la navigation du piéton dans le monde réel présente plus d'aléas car l'agent réel explore l'espace selon son libre arbitre et non pas systématiquement suivant l'itinéraire calculé sur le mesh. Ce compromis entre libre arbitre de l'utilisateur et assistance de la carte pour la localisation nous semble

¹⁴ Building Information Model

mieux géré avec des graphes de navigation. Aussi, pour une application où le piéton souhaite une proposition d'itinéraire à suivre, l'utilisation d'un mesh est recommandée. Dans les cas où le libre arbitre du piéton est plus important, il est préférable d'adopter un graphe de navigation. Toutefois, ce dernier doit être réaliste afin de couvrir un large éventail de trajets possibles.

III.3 Nouveau graphe dans les espaces non-contraints par les obstacles

III.3.1 Difficultés de modélisation des espaces non-contraints par les obstacles

Que ce soit pour les mesh ou pour les graphes, les réseaux de navigation sont générés grâce à l'identification des obstacles. Ces derniers étant exclus de la carte, l'espace navigable est géométriquement contraint et l'apport de la carte revient principalement à fournir l'information d'orientation, laquelle est donnée par les linéaires qui matérialisent les voies piétonnes en extérieur et les couloirs en intérieur, ou bien les itinéraires pré-calculés dans le cas des mesh. Ces modèles sont de ce fait mal définis dans les espaces non contraints par les obstacles tels que les halls ou les places. Une alternative consiste à représenter ces espaces sous forme de maillages réguliers [64], ce qui reflète une absence de contraintes et donc une absence de mesure cartographique pour aider l'algorithme de navigation. Ce type de représentation est adopté dans la section VI.2.2.2 qui livre une analyse détaillée des problèmes liés aux maillages réguliers. Entre autres, cela engendre une surestimation de distance dans le processus PDR à cause de la géométrie de la maille (Un trajet linéaire est en effet découpé en plusieurs sous-trajets qui ne sont pas colinéaires). Ils sont donc plus adaptés pour des applications ne devant pas fonctionner en temps réel car cela permet de réaliser un filtrage a posteriori et de lisser l'effet des non-linéarités artificielles du trajet calculé [65].

III.3.2 Adaptation de la notion de portail pour la construction du graphe

Comme alternative au problème des espaces non-contraints par les obstacles, nous proposons d'utiliser l'algorithme A* qui est un algorithme de planification couramment utilisé pour la navigation des agents virtuels et des véhicules, pour calculer un ensemble d'itinéraires formant un graphe dont l'architecture conserve la notion d'orientation et permet par conséquent la calibration des caps PDR. Ce graphe est construit sur la base d'un ensemble de points appelés « portails » entre lesquels des itinéraires optimaux, selon un critère adapté au profil de mobilité du piéton (III.1.1), sont calculés. Lorsque l'utilisateur a un profil de mobilité sans difficulté particulière, le critère d'optimisation correspond tout simplement à la distance du trajet.

L'approche proposée dans cette thèse s'inspire de travaux qui se sont intéressés à la planification de trajets piétons d'un point de vue cognitif. Nous exploitons la notion de « scène de décision » définie dans [56] comme tout « endroit que l'on peut pénétrer et quitter et qui est physiquement borné par des bâtiments et d'autres obstacles solides infranchissables ». Une scène de décision est présentée dans l'état de l'art comme une destination, du moins intermédiaire, ce qui la différencie a priori des passerelles, des couloirs, ou des voies piétonnes. Ces scènes de décisions ont des ouvertures appelées « portails » qui permettent le flux piéton (i.e. passages obligatoires pour accéder à (ou sortie de) la scène). Ces termes étant maintenant définis, il reste à noter que le piéton optimise son trajet sous la contrainte de deux facteurs principaux. Le premier est l'isovist, qui est l'espace visible depuis sa position. Ce dernier est principalement déterminé par les obstacles qui ont un impact à la fois sur la visibilité et sur la forme du trajet [33]. Le deuxième est l'ensemble des portails qui permettent aux piétons de transiter d'une scène de décision vers une autre. L'étude [56] a en effet montré que la notion de portail avait un apport significatif dans la planification des trajets piétons par rapport aux méthodes dites « kernels » qui sont basées sur les centres géométriques des scènes de décision. La Figure 33 montre la différence entre un graphe basé sur des « kernels », correspondant au « skeleton representation » construit à partir d'un ensemble de « decision points », et un graphe basé sur la notion de « portal » qui correspond au « completed graph » de la figure. L'optimisation de distance est en effet plus réaliste avec ce dernier car les centres des scènes de décisions sont rarement atteints par le piéton comme le voudraient les méthodes purement géométriques. Ce point de vue est adopté dans cette étude grâce à une adaptation de ce principe aux espaces indoor et outdoor.

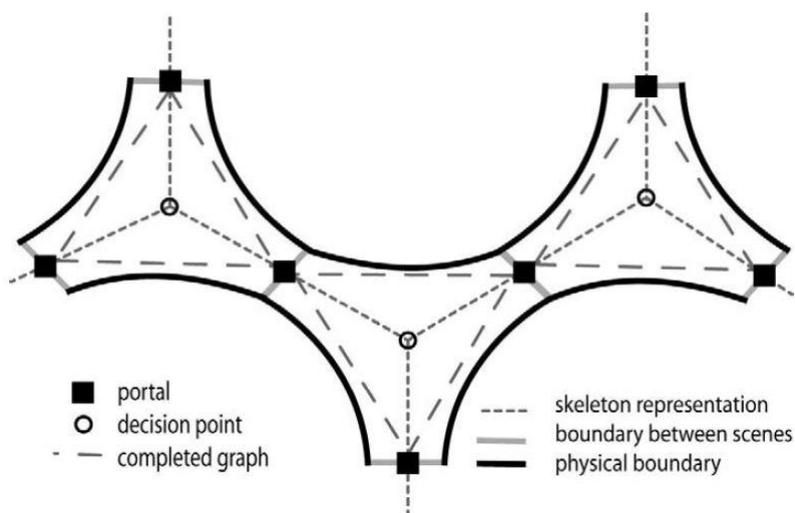


Figure 33 : Scènes de décision et portails dans [56]

Ici, les scènes de décisions sont étendues aux voies piétonnes (outdoor) et aux couloirs, ce qui est justifiable car ces deux espaces répondent à la définition donnée dans [56], à l'exception que les obstacles délimitant une voie piétonne en extérieur sont fictifs car ils ne sont pas physiquement infranchissables, mais ils le sont d'un point de vue réglementaire (Figure 34). Ainsi, l'ensemble des portails est donné par les extrémités des couloirs, les entrées de magasins ou de salles de manière générale, les entrées de bâtiments ainsi que les extrémités des voies piétonnes.



Figure 34 : Bordure réglementaire entre une voie cyclable et une voie piétonne

III.3.3 Génération d'un graphe basé sur les portails

La méthodologie proposée au paragraphe précédent a été mise en œuvre pour générer un graphe de navigation dans un espace non-contraint par les obstacles. Il s'agit à la fois d'un espace de transition Indoor-Outdoor mais aussi d'un espace ouvert, dans le sens non-contraint par des obstacles. La nouvelle définition des portails est mise en œuvre pour les voies piétonnes en extérieur, à l'entrée du bâtiment, aux entrées des magasins et aux différents couloirs (Figure 35). Le graphe est calculé en reliant chaque couple de portails par un itinéraire calculé avec l'algorithme A*. Ici, l'itinéraire optimal entre deux points de visibilité (i.e. deux points pouvant être reliés par une ligne droite sans que cette dernière ne traverse un obstacle) est linéaire. Cela ne serait pas forcément le cas si le critère d'optimisation était autre que la distance, comme le revêtement de surface, la pente, ou tout autre critère. Les résultats de localisation obtenus avec ce graphe sont donnés à la section VI.2.2.3.

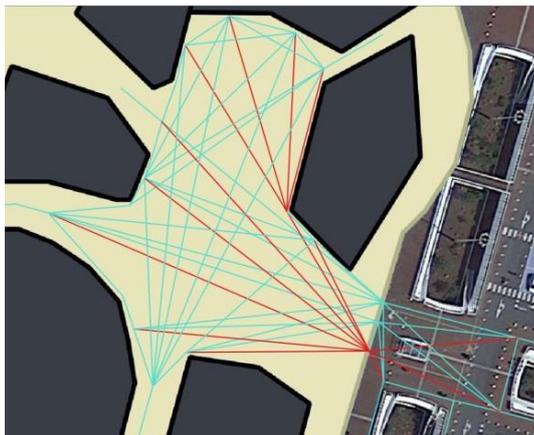


Figure 35 : Le graphe de navigation correspond à l'ensemble des itinéraires bleus et rouges. Les parties sélectionnées en rouge sont exploitée dans le texte pour expliquer le principe de construction du graphe

Chapitre IV

IV. LIAISON ENTRE LA CARTE ET LA SIGNATURE DE MOUVEMENT	49
IV.1 Etat de l'art sur les méthodes d'exploitation de la carte pour la localisation	49
IV.1.1 Carte de chaleur traduisant une probabilité d'occupation de la carte	49
IV.1.2 Adaptation des modèles dynamiques à la nature du mouvement	49
IV.1.3 Mesure de position grâce à des points d'intérêt (POI)	50
IV.1.4 Correction de la trajectoire par assimilation avec des itinéraires pré-calculés	50
IV.2 Focus sur les défis de la transition indoor-outdoor	51
IV.2.1 Intérêt de la distinction indoor-outdoor (IO)	51
IV.2.2 Définition de l'indoor et de l'outdoor dans l'état de l'art	52
IV.2.3 Technologies de détection IO existantes	53
IV.2.4 Le problème de généralisation	55
IV.3 Principales méthodes de classification supervisée	56
IV.3.1 Formulation du problème de classification	56
IV.3.2 Algorithmes de classification	61
IV.3.3 Algorithmes de sélection des descripteurs pertinents	63
IV.4 Méthodologie proposée pour la mise à jour de position grâce à des POIs	67
IV.4.1 Approche proposée	67
IV.4.2 Typologie des POIs à partir d'une classification de mouvement	69
IV.4.3 Collecte des signaux	72
IV.4.4 Indexation du signal	74
IV.4.5 Calcul des descripteurs	80
IV.4.6 Variabilité des longueurs de fenêtres dans le processus de détection	82

IV. Liaison entre la carte et la signature de mouvement

Ce chapitre s'intéresse à la détection de points d'intérêt (POI) pour fournir des mesures de position régulières dans les environnements indoor et outdoor. L'organisation du chapitre s'articule comme suivant : la section IV.1 présente l'état de l'art en matière de reconnaissance de mouvement et d'aide à la localisation grâce aux données de la carte, la section IV.2 présente les défis de la reconnaissance de l'indoor et de l'outdoor et de son intérêt pour la localisation, la section IV.3 présente succinctement les trois algorithmes de reconnaissance et de sélection des descripteurs pertinents utilisés pour la reconnaissance des POI, et la section IV.4 présente le détail de la méthodologie proposée pour mettre en place une base de données de points d'intérêts standards détectables par reconnaissance automatique sur le signal.

IV.1 Etat de l'art sur les méthodes d'exploitation de la carte pour la localisation

Cette section présente différentes manières de rendre la carte plus informative en termes de contexte spatial grâce à des méthodes de reconnaissance automatique. Notons que l'intérêt ici consiste uniquement à montrer le lien établi entre donnée cartographique et signature du mouvement piéton sans expliciter comment ce lien est intégré dans le calcul de position. Ce dernier aspect est traité plus loin dans ce document, plus précisément à la section V.3.5.

IV.1.1 Carte de chaleur traduisant une probabilité d'occupation de la carte

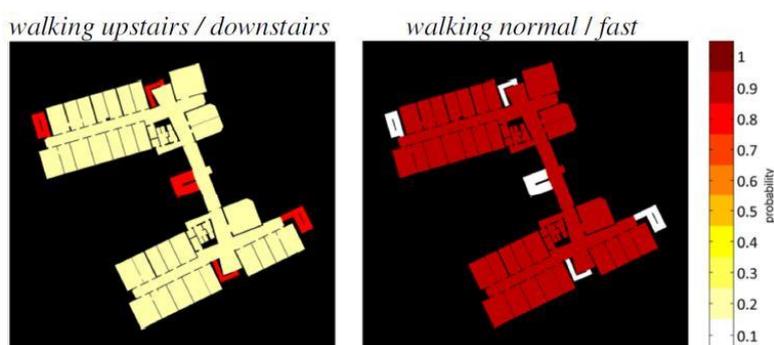


Figure 36: Carte de probabilité d'occupation en fonction de la classe de mouvement [66]

La localisation sur la carte et la nature du mouvement piéton sont deux éléments dépendants l'un de l'autre. Une reconnaissance de mouvement devrait donc pouvoir influencer le calcul de position et cela a été largement investigué dans l'état de l'art. Nous citons en premier exemple le calcul dynamique d'une carte de chaleur qui traduit la probabilité d'occupation de certains endroits de la carte en fonction du mouvement piéton. Cette approche naît de la simple idée qu'un piéton qui marche droit a de faibles chances d'être dans un escalier ou dans un ascenseur. Le contraire est également vrai. Ainsi, grâce à une sémantisation de la carte à travers la désignation des ascenseurs et des cages d'escaliers (Figure 36), les auteurs sanctionnent les zones à faible probabilité d'occupation et intègrent cette information dans le calcul de position [66].

IV.1.2 Adaptation des modèles dynamiques à la nature du mouvement

Dans la même optique que précédemment, la probabilité d'occupation des couloirs est augmentée dans [66] lorsque la cadence de marche est normale voire soutenue. Pour ce faire, différentes classes de vitesses de marche sont établies. Mais cette classification a surtout pour apport de tenir compte de la dynamique de la marche afin d'adapter les modèles de longueurs de pas. En effet, plus la vitesse de marche est importante, plus la longueur de pas est grande. Cette relation est prise en compte en intégrant un facteur d'échelle dans le modèle de longueur de pas. Sa valeur est déterminée empiriquement pour chacune des classes de vitesse de marche.

Dans le contexte de l'adaptation des modèles dynamiques, la reconnaissance de mouvement a également servi dans [67] pour distinguer les phases statiques qui sont accompagnées d'un

changement de position des phases statiques où la position du piéton ne varie pas, ce qui est le cas par exemple dans les ascenseurs ou les escalator. La reconnaissance du mode de déplacement permet alors de remplacer le processus de détection de pas et de le remplacer par un modèle plus adéquat. Notons que la détection des escalators et ascenseurs dans [67] est réalisée par reconnaissance sur les signaux d'un magnétomètre et d'un baromètre.

IV.1.3 Mesure de position grâce à des points d'intérêt (POI)

A certains endroits de la carte, il est possible de lier le mouvement piéton directement à une position grâce à une détection de point d'intérêt (POI). Ce dernier correspond à un ponctuel sur la carte où le signal présente une signature identifiable. C'est typiquement le cas des coins de bâtiments. En effet, c'est l'endroit où la variation du cap de marche est la plus importante (Figure 37) [68]. Un simple seuillage de la vitesse angulaire permet alors de détecter les coins de bâtiments sans avoir recours à un algorithme d'apprentissage. Il est aussi possible de faire participer le piéton à la saisie manuelle de POIs dans des applications à portée collaborative dans le même objectif.

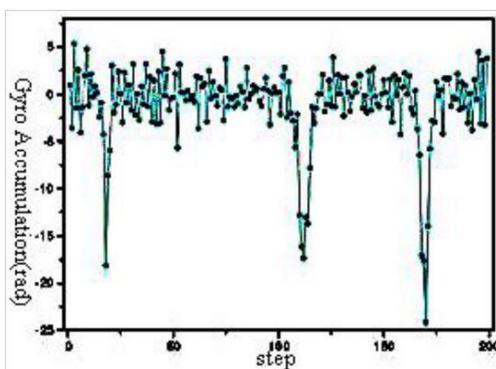


Figure 37: Détection des coins de bâtiment sur le signal du gyromètre

IV.1.4 Correction de la trajectoire par assimilation avec des itinéraires pré-calculés

Dans [69], une classification de mouvement est réalisée afin de détecter les transitions entre des endroits prédéfinis de la carte. Une étape préalable consiste à construire une base de données des séquences de mouvements assignées à des déplacements sur la carte. Aussi, à partir d'une première position et d'une séquence de mouvements issue de la classification, un calcul de corrélation permet de confirmer ou non la correspondance entre la séquence calculée et un vecteur de transition stocké dans la base de données des différents itinéraires enregistrés. Si le test est positif, une mesure de position devient disponible et permet de calibrer la trajectoire PDR. La mise en application de cette méthode avec des capteurs fixés au corps a permis d'atteindre un taux de reconnaissance de 91.8%. Néanmoins, c'est une approche qui est sensible à la dérive des caps de marche et aux erreurs de distance. En effet, mesurer une séquence de mouvements erronée risque d'entraîner des mauvais appariements. Par ailleurs, c'est une approche qui est fort dépendante de la structure du bâtiment et donc peu éligible à une éventuelle généralisation.

Une approche semblable consiste à faire du curve-to-curve matching. Cela désigne un algorithme d'appariement dont la solution s'obtient après un certain temps de convergence. L'appariement se fait entre la trajectoire PDR reconstruite de manière récursive et un graphe de navigation. A chaque fois qu'une mesure est disponible un triangle est calculé. Les éléments de ce triangle sont la distance parcourue, une différence de cap par rapport au trajet précédent, ainsi qu'une différence d'élévation par rapport à la position précédente (Figure 38).

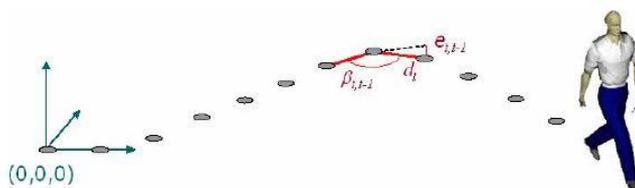


Figure 38: Calcul de polygline 3D à l'aide de capteurs inertiels et d'un baromètre [70]

Une détection de POI est gérée par seuillage. Les fortes différences de cap sont associées aux coins du bâtiment, tandis que les importants changements d'élévation correspondent aux changements d'étages. Les POI sont des nœuds faisant partie du graphe de navigation. Au fur et à mesure que la trajectoire PDR est calculée, une polyligne en 3 dimensions dont les extrémités sont des POI est construite (Figure 39).



Figure 39: Détection de POIs par analyse de la trajectoire PDR [70]

A partir d'un POI détecté et de la polyligne formée par la trajectoire, un calcul d'appariement est effectué afin d'assimiler la polyligne au graphe. L'appariement est d'autant plus efficace que le nombre de mesures augmente. En effet, c'est une approche multi-hypothèses implémentée grâce à un filtre particulaire. Les possibilités d'appariement sont de moins en moins nombreuses au fil du temps grâce à l'augmentation des mesures disponibles. L'exploration du graphe de navigation n'est pas progressive comme il est commun dans les systèmes PDR. En effet, chacun des segments est pondéré à chaque instant (Figure 40) en fonction de sa correspondance avec les dernières mesures. La section V.2 s'intéressera plus en détail de l'implémentation d'un filtre particulaire avec différents réseaux de navigation, notamment les graphes.

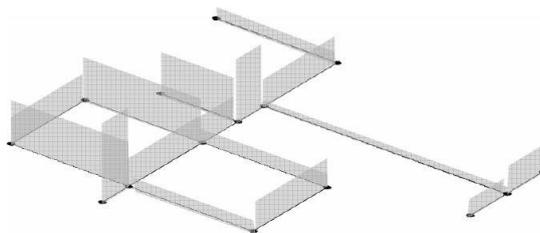


Figure 40: Pondération des segments en fonction de la correspondance avec la polyligne reconstruite [70]

IV.2 Focus sur les défis de la transition indoor-outdoor

IV.2.1 Intérêt de la distinction indoor-outdoor (IO)

La reconnaissance automatique des environnements indoor et outdoor présente des défis liés à la définition de ces deux espaces ainsi qu'aux technologies déployées pour les reconnaître. Cette reconnaissance est cependant cruciale en navigation car elle permet d'adapter les algorithmes de localisation tout en assurant une meilleure performance énergétique, ce qui est considérablement important pour les applications mobiles de LBS¹⁵. Sur un plan technique, la reconnaissance de l'indoor et de l'outdoor permet de sélectionner les mesures et les modèles de positionnement les plus efficaces. À titre d'exemple, le signal GNSS peut être intercepté en indoor mais sa qualité est dégradée, ce qui revient à introduire une mesure affectée de plusieurs erreurs (multi-trajet, atténuation du signal, mauvaise géométrie des satellites visibles) qui agissent sur la précision de la position obtenue. Il convient alors de limiter sa participation au processus de localisation et d'accorder plus de confiance au réseau de navigation car sa géométrie est plus contraignante et souvent mieux connue en intérieur qu'en extérieur. D'un point de vue énergétique, il est admis qu'une recherche constante de signal GNSS agit fortement sur la consommation d'énergie [71] et pose des problèmes de veille au niveau des applications mobiles. La reconnaissance de l'indoor et de l'outdoor permet d'améliorer l'aspect énergétique de manière à ce que les mesures qui ne sont pas censées participer au processus de localisation soient désactivées.

Dans ce travail, l'intérêt est porté sur la détection des instants d'accès aux bâtiments, ce qui est différent de la reconnaissance de l'indoor et de l'outdoor mais qui a été construit sur la base de

¹⁵ Location Based Service

l'existant en matière de reconnaissance IO. Cette différence se trouve à la fois dans la suppression du besoin de distinguer l'indoor de l'outdoor, mais elle concerne aussi l'information qui en découle, c'est-à-dire une mesure de position et non plus une adaptation algorithmique en fonction de l'environnement. Ce dernier aspect étant géré autrement dans ce travail par exploitation du signal GNSS qui peut se dégrader aussi bien en indoor qu'en outdoor selon les masques, etc. La mesure de position au moment de la transition IO est d'autant plus importante que cette phase est marquée par une accumulation d'erreurs démontrée à la section VI.2.2.2. De manière succincte, la première source d'erreur est le graphe de navigation qui manque généralement de contrainte géométrique au voisinage des entrées des bâtiments. La seconde source d'erreur, qui permet en temps normal de combler les imprécisions du graphe de navigation lorsque les contraintes géométriques sont faibles, est la dégradation du signal GNSS. Aussi, assurer une localisation continue entre l'extérieur et l'intérieur constitue un réel défi en navigation aujourd'hui, d'abord parce qu'aucune technologie ne s'est avérée efficace à la fois en indoor et en outdoor, et ensuite parce qu'il n'existe à ce jour aucune solution universelle pour la reconnaissance des deux environnements. Pour mieux étudier ce dernier aspect, les prochaines sections s'intéressent à la définition de l'indoor et de l'outdoor et aux différentes technologies et méthodes adoptées dans la littérature pour discriminer la transition IO.

IV.2.2 Définition de l'indoor et de l'outdoor dans l'état de l'art

La distinction entre l'indoor et l'outdoor est évidente d'un point de vue lexical. L'indoor correspond aux infrastructures contraintes par les murs et un toit, tandis que l'outdoor correspond à l'extérieur. En matière de reconnaissance automatique, cette distinction devient relative aux technologies considérées. En termes de réception GNSS, une salle avec de grandes baies vitrées n'est pas forcément considérée comme un espace indoor car un certain nombre de satellites sont visibles depuis cette salle, pourtant il s'agit bien d'un espace indoor d'un point de vue lexical. Pour pallier cette difficulté, plusieurs classes ont alors été introduites dans l'état de l'art pour une description plus riche des types d'environnements connus par le piéton. La classification prédominante consiste à considérer l'espace indoor, l'espace outdoor, ainsi qu'une troisième classe dite « semi-outdoor » [72]. Cette classification est illustrée dans la Figure 41. Elle est particulièrement déterminée par l'exposition à la lumière du soleil.

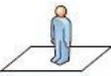
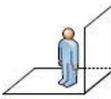
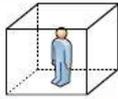
Environment	Outdoor	Semi-outdoor	Indoor
Definition	Outside a building	Near a building	Inside a building
Example			
Scene			

Figure 41 : Définition de l'indoor, outdoor et du semi-outdoor dans [72]

Une classification plus fine a été proposée dans [73] où l'on distingue l'open-outdoor, le deep-indoor, le semi-outdoor et le light-indoor (Figure 42). Une classification similaire est aussi proposée dans [74]. Cette classification est principalement dépendante de la disponibilité du signal GNSS. Le deep-indoor est ainsi défini par une absence totale de signal GNSS. Un long tunnel serait ainsi considéré de classe deep-indoor, bien qu'il ne s'agisse pas d'un bâtiment. La frontière entre le semi-outdoor et le light indoor reste quant à elle assez ambiguë.

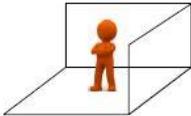
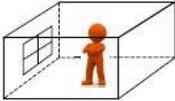
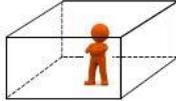
Environment	Open Outdoors	Semi-Outdoors	Light Indoors	Deep Indoors
Definition	Outside a building	Near a building	In a room with windows	In a room without windows
Example				

Figure 42 : Distinction de quatre types d'environnements dans [73]

Suite à cette brève présentation des différentes classes d'environnements suggérées dans l'état de l'art, il semble qu'il existe un écart significatif entre la définition lexicale commune de l'indoor et de l'outdoor et les différentes classes d'environnements relayées par la littérature. Nous expliquons cela principalement par la dépendance éminente entre les technologies adoptées et les frontières qui en découlent et qui forment les différentes classes d'environnements vues dans la section précédente. La prépondérance de la classification « indoor, outdoor et semi-outdoor » montre notamment que l'une des technologies les plus utilisées dans ce sens est le GNSS. La section suivante démontre ce lien en s'intéressant aux principales méthodes existantes aujourd'hui pour distinguer l'indoor et l'outdoor.

IV.2.3 Technologies de détection IO existantes

Plusieurs technologies ont été proposées pour détecter l'indoor et l'outdoor. En pratique, il s'agit souvent de détecter soit l'indoor, soit l'outdoor, soit une catégorie entre les deux, avec une absence de définition exacte de la transition IO.

IV.2.3.1 Capteurs cellulaires - Champ magnétique - Luminosité

Une approche populaire est la méthode IODetector qui combine trois détecteurs IO dont un capteur de luminosité, des capteurs cellulaires et un capteur de champ magnétique [72]. Elle distingue les classes « indoor, outdoor et semi-outdoor ». L'étude exploite notamment la différence de l'intensité lumineuse entre l'intérieur et l'extérieur durant le jour, la variation du champ magnétique qui est plus importante en intérieur, ainsi que la puissance du signal radio (RSS) envoyé par les antennes cellulaires qui est plus importante à la réception en extérieur. Avec ces trois capteurs, trois modules de reconnaissances sont établis et leurs résultats sont agrégés pour une détection finale obtenue avec une latence de 10 secondes. Une loi probabiliste de transition est intégrée au processus de reconnaissance, favorisant le passage par le semi-outdoor avant de transiter de l'indoor vers l'outdoor et vice-versa. Les signaux d'apprentissage sont collectés selon 19 trajets couvrant 84 sites différents sur une durée d'un mois. Les performances sont supérieures à 80% de précision globale. Cette méthode est principalement réputée pour sa bonne performance en conditions de luminosité optimale mais aussi pour sa dégradation aux heures où le soleil est près, voire au-delà, de l'horizon ou lorsque les capteurs ne sont pas bien exposés à la lumière (ex. dans la poche) [75]. Une approche utilisant uniquement un capteur de lumière porté à la tête a également été mise en œuvre dans [76] pour classifier trois types d'environnements. Il s'agit des environnements indoor, outdoor et semi-outdoor. Cette approche n'exploite pas uniquement l'intensité de la lumière mais permet également une décomposition de cette dernière selon les canaux Rouge Vert et Bleu (RGB) tout en bénéficiant d'une exposition à la lumière optimale grâce au portage du dispositif à la tête. Les performances obtenues sur des données test sont de l'ordre de 86% de précision globale avec des algorithmes d'apprentissage tels que Random Forest ou Naïve Bayes. La latence y est réduite à 5 secondes, ce qui est remarquablement faible vis-à-vis de l'existant.

IV.2.3.2 Signal Sonore

La détection de la transition IO a été traitée par exploitation du son dans [77]. Cette étude réalise une classification binaire de l'indoor et de l'outdoor par mesure de la corrélation entre le signal envoyée par un microphone et sa réverbération. Le classifieur est établi par simple méthode de seuillage binaire sur un « score » de réverbération. Cette méthode semble être une bonne solution étant donné que la sonde sonore est envoyée depuis le microphone (qui pourrait être intégré au smartphone), ce qui signifie que la grandeur physique mesurée est la même quel que soit l'environnement. Elle

annonce par ailleurs une précision globale de 96.79% avec une latence de 3.81, ce qui est minimal par rapport à l'état de l'art et qui correspond à la durée approximative nécessaire pour rentrer dans un bâtiment (ou ouvrir une porte d'accès).

IV.2.3.3 Température

La détection IO a été traitée par exploitation de la mesure de température dans [78]. Le principe de la détection consiste principalement à comparer la température mesurée avec la température extérieure qui est donnée par un modèle terrestre, ce qui suppose une connaissance plus ou moins précise de la localisation du capteur. Dans les cas où l'écart est important, cela signifie que l'utilisateur est probablement en intérieur. Cette méthode a été baptisée TempIO et a obtenu une précision globale de 81%. Cette performance atteint 91% lorsque le modèle de température est remplacé par un thermomètre extérieur.

IV.2.3.4 GNSS

La puissance du signal GNSS et le nombre de satellites visibles sont exploités dans [74] pour distinguer quatre classes d'environnements correspondant à « indoor », « intermediate », « urban » et « open sky ». La classe « intermediate » est l'équivalent du semi-outdoor, tandis que « urban » et « open sky » permettent de distinguer les zones urbaines denses des zones dégagées. Les espaces indoor comprennent les salles fermées malgré la présence de grandes baies vitrées, tandis que la classe « intermediate » correspond à des endroits non fermés (voir article pour plus d'illustrations). La reconnaissance est réalisée de manière hiérarchisée de façon à ce que les deux classes « urban » et « open sky » ne soient séparées que si les deux autres classes n'ont pas été précédemment détectées. L'apprentissage est réalisé avec un modèle de Markov Caché du premier ordre où le modèle de transition est une fonction identité tandis que le modèle d'observation est basé sur la mesure GNSS. Un taux de reconnaissance de 88% est obtenu sur des données test, toujours avec l'inconvénient énergétique lié à la recherche constante de signal GNSS.

IV.2.3.5 Signal WIFI

L'étude [79] s'est intéressée à l'apprentissage des espaces indoor et outdoor grâce à des fingerprints WIFI. Un fingerprint correspond à l'ensemble des signaux marqués temporellement et reçus depuis plusieurs balises, plus précisément de leur puissance (RSSI). Ces fingerprint sont ensuite clusterisés par mesure de corrélation. Le graphe de transition (Figure 43) permet de lier l'ensemble des clusters, lesquels sont des nœuds, par des connexions qui traduisent une succession temporelle entre les nœuds (i.e. si deux fingerprints appartenant à chaque cluster ont été collectés à deux instants successifs t et $t+1$).



Figure 43 : Graphe de transition WIFI [79]. Les nœuds noirs correspondent aux espaces indoor tandis que les autres correspondent à l'outdoor

Chaque nœud est un individu d'apprentissage. Les descripteurs considérés sont le nombre de nœuds voisins, la puissance moyenne du signal reçu par les nœuds voisins, le nombre moyen des balises interceptées par les nœuds voisins, ainsi que le nombre moyen de fingerprints des nœuds voisins. La notion de voisinage est contrôlée par un seuil de distance. Plusieurs classifieurs sont testés et les meilleures performances sont obtenues avec les algorithmes Random Forest et Gradient Boosting avec des précisions globales de 93%. La latence moyenne de détection est de 4.3 s pour l'algorithme Gradient Boosting pour la transition outdoor-indoor et de 16.6s pour la transition indoor-outdoor, ce qui démontre que le sens de la transition agit ici sur la latence de détection.

IV.2.3.6 Pression

La mesure de pression est exploitée dans [80] pour détecter les ouvertures des portes d'accès aux bâtiments, les ascenseurs, les escaliers et les phases de marche normale. Elle est réalisée dans une optique d'aide à la surveillance pour détecter les intrusions dans les bâtiments. Cette étude est particulièrement intéressante car peu de recherches ont traité de l'éventuelle contribution du baromètre au processus de la reconnaissance IO. L'étude [80] affirme notamment que le baromètre seul peut discriminer l'ensemble des classes susmentionnées, grâce à trois descripteurs reflétant la vitesse de variation du signal, son écart type et le nombre de fois que le signal croise la valeur moyenne sur une fenêtre de 3 secondes. La précision de détection des ouvertures de portes annoncée est supérieure à 99%, la sensibilité relative aux classes n'est pas étudiée. Cette approche nous semble néanmoins non adaptée au contexte de la navigation car la collecte du signal a été réalisée dans un mode statique pour la détection des ouvertures des portes. Ce mode d'acquisition a permis d'isoler une signature de pression qui s'ébruite rapidement lorsque l'ouverture de porte est réalisée alors que le capteur est tenu dans la main. Nous illustrons cette différence la section IV.4.4.1 par comparaison de la signature du signal dans le cas statique et dans un cas de déplacement avec un capteur à la main.

IV.2.3.7 Détection IO par analyses de l'activité du piéton

Chacune des technologies mentionnées précédemment exploite les propriétés physiques de l'environnement pour détecter la transition IO. Or ces propriétés peuvent varier plus ou moins aléatoirement au sein des deux espaces et provoquer des confusions dans la reconnaissance IO. Pour remédier à la dépendance à l'environnement, l'étude [75] a proposé de classifier l'indoor et l'outdoor en fonction de l'activité de l'utilisateur. Cette étude suggère notamment d'exploiter la différence des distributions des activités piétonnes entre l'indoor et l'outdoor (Figure 44). Elle intègre les classes de marche, de repos (position assise ou allongée), de montée/descente d'escaliers, et de montées/descentes d'ascenseurs. L'apprentissage est réalisé grâce à un modèle de Markov caché où les variables d'état sont {indoor, outdoor} et les observations sont les classes de mouvement. Cette démarche reste néanmoins discutable sur le principe, car ses hypothèses ne sont pas toujours vraies (ex. présence d'escaliers principalement en intérieur). Par ailleurs, les performances de reconnaissance optimales sont obtenues pour une fenêtre de largeur temporelle d'une minute, ce qui reste assez important par rapport à l'existant en matière de reconnaissance IO.

Activities	Attributes	Observation results— indoor and outdoor
Sitting, lying	Stationary	More indoor than outdoor
Walking	Moving: Making turns	Moving duration is longer outdoor than indoor; more turns indoor; walking faster outdoor than indoor
Going upstairs and downstairs	Vertical moving	Mostly indoor
Standing in elevators	Sharp vertical moving	Mostly indoor

Figure 44 : Distribution des états {indoor, outdoor} selon la classe d'activité du piéton

IV.2.4 **Le problème de généralisation**

En plus des avantages et des limites propres à chaque technologie, les différentes méthodes de détection IO, ainsi que les méthodes d'apprentissage de manière générale, sont affectées par la diversité des environnements et la diversité des utilisateurs. Le problème de généralisation de ces méthodes a notamment été étudié dans [81]. Il est en effet admis que les modèles d'apprentissage/classification sont nettement moins performants lorsqu'ils sont testés dans des

environnements nouveaux. Par exemple, la méthode IODetector a obtenu une précision globale de seulement 71.30% dans [81], et de 55.45% en absence de lumière. Le même constat a été établi pour l'utilisation du signal GNSS avec une précision globale allant de 70 à 80%. Cette dégradation est aussi accompagnée d'une latence plus importante. Notons qu'une latence de détection de 10 secondes correspond approximativement à un nombre de 15 à 20 pas pour une fréquence de marche inférieure à 2 pas par seconde. Cela équivaut donc à une distance pouvant atteindre 15m pour une longueur de pas de 75cm. Une telle latence est tolérable si l'objectif de la détection est l'adaptation de l'algorithme de localisation au contexte de navigation. En revanche, cela reste largement insuffisant si l'objectif consiste à dégager une information de position, ce qui est le cas dans cette étude. Cela signifie que les performances de la reconnaissance sont aussi importantes que la latence de détection. Pour compenser ces limites, les auteurs de [81] ont alors proposé de réaliser un apprentissage semi-supervisé afin de s'adapter automatiquement aux nouveaux environnements. Cette approche permettrait effectivement d'améliorer la généralisation des algorithmes. Elle est cependant vouée à donner des modèles de moins en moins efficaces car à chaque nouvelle étape d'apprentissage semi-supervisé des erreurs sont également introduites.

IV.3 Principales méthodes de classification supervisée

IV.3.1 Formulation du problème de classification

Nous disposons d'une base de données sous forme de table contenant n lignes correspondant à n individus d'apprentissage et p statistiques pour leur description. Cette base de données est exprimée sous forme d'une matrice \mathbf{X} . Un vecteur \mathbf{Y} est dédié à la désignation des classes correspondant à chaque individu. Nous nous intéressons dans ce paragraphe à la formulation mathématique du problème d'apprentissage et à la construction d'un classifieur qui permet de prédire la classe de chaque individu à partir de ses statistiques descriptives.

IV.3.1.1 Présentation des données

Pour une matrice $\mathbf{X} \in M(n, p)$ où $M(n, p)$ est l'ensemble des matrices à valeurs réelles de dimension $n \times p$:

$$\mathbf{X} = \begin{bmatrix} x_1^1 & \dots & x_1^p \\ \vdots & \ddots & \vdots \\ x_n^1 & \dots & x_n^p \end{bmatrix} \quad \text{E. 48}$$

Le vecteur ligne $\mathbf{x}_i = [x_i^1 \dots x_i^p]$ correspond à un l'individu i et un vecteur colonne $\mathbf{x}^j = [x_1^j \dots x_n^j]^T$ correspond à l'attribut ou descripteur j . La matrice \mathbf{X} peut s'écrire :

$$\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n]^T \quad \text{E. 49}$$

ou bien

$$\mathbf{X} = [\mathbf{x}^1, \dots, \mathbf{x}^p] \quad \text{E. 50}$$

A chaque individu \mathbf{x}_i est associée une classe labellisée (ou étiquetée) y_i . Le modèle qui permet d'associer à chaque individu \mathbf{x}_i une classe de valeur y_i est appelé classifieur. Il s'agit du prédicteur f (E. 51). Dans la suite, nous notons \mathbf{x} un individu quelconque et y sa classe associée :

$$\begin{aligned} f : \mathfrak{R}^p &\rightarrow \mathfrak{R} \\ \mathbf{x} &\mapsto y = f(\mathbf{x}) \end{aligned} \quad \text{E. 51}$$

On appelle ensemble d'apprentissage l'ensemble donné par :

$$L = \{\mathbf{x}_i, y_i\}_{i \in [1, n]} \quad \text{E. 52}$$

Nous nous situons dans le cadre de la classification supervisée qui consiste à utiliser l'ensemble d'apprentissage L pour calculer f . L'approche de classification aurait été non-supervisée si les valeurs $\{y_i\}_{i \in [1, n]}$ étaient manquantes.

IV.3.1.2 Erreur du modèle d'apprentissage

IV.3.1.2.1 Variance et biais d'un prédicteur

L'erreur d'un prédicteur peut être décomposée en trois éléments : Une erreur irréductible, un biais et une variance. Nous donnons un bref aperçu de la nature de ces différentes entités afin de comprendre en quoi les algorithmes utilisés permettent de calculer des prédicteurs optimaux.

Parce que les notions de variance et de biais ont davantage été définies dans le cas de la régression, nous les présentons dans ce cadre avant de transposer le principe de leur décomposition au cas de la classification.

Erreur de généralisation du prédicteur f :

Commençons par noter que $y_{vrai} = y + \varepsilon$ où ε est une variable aléatoire normale centrée de variance σ_ε^2 . L'erreur de généralisation du prédicteur f s'écrit :

$$Err(f) = \frac{1}{n} \sum_{i=1}^n [C(f(\mathbf{x}_i), y_{ivrai})] \quad E. 53$$

Où C est une fonction coût qui évalue l'écart entre la prédiction et la valeur vraie de la sortie y . L'exemple usuel de la fonction coût est l'erreur moyenne quadratique qui s'écrit :

$$C(f(\mathbf{x}), y_{vrai}) = |f(x) - y_{vrai}|^2 \quad E. 54$$

Erreur moyenne de généralisation :

Considérons par ailleurs l'ensemble des fonctions $\{f_G\}_{G \in [1, N_L]}$ des modèles construits à partir de différents ensembles d'apprentissage $\{L_G\}_{G \in [1, N_L]}$ de même distribution. Ces modèles s'écrivent chacun :

$$\begin{aligned} f_G : \mathfrak{R}^p &\rightarrow \mathfrak{R} \\ \mathbf{x} &\mapsto y = f_G(\mathbf{x}) \end{aligned} \quad E. 55$$

L'erreur moyenne de généralisation est alors définie par :

$$Err_L(f_G) = \frac{1}{N_L} \sum_{G=1}^{N_L} Err(f_G) \quad E. 56$$

Prédicteur de Bayes :

Un modèle f_B est un modèle de Bayes si pour tout modèle f_G construit à partir d'un ensemble d'apprentissage L_G nous avons l'inégalité :

$$Err(f_B) \leq Err(f_G) \quad E. 57$$

Nous retiendrons que dans la plupart des cas le modèle f_B ne peut être obtenu car la taille nécessaire d'individus d'apprentissage pour le calculer augmente exponentiellement avec le nombre de descripteurs considérés. Dans les cas réels, on ignore la distribution effective des classes et on ne peut qu'approcher f_B . De même, l'erreur $Err(f_B)$ est irréductible car elle résulte de processus aléatoires inhérents aux données. Cette erreur est appelée résidu.

Décomposition de la variance et du biais dans le cas de la régression :

Après avoir introduit la notion de résidu et le modèle de Bayes, notons que tout prédicteur a une erreur pouvant être décomposée selon l'égalité suivante (Voir [82] pour une démonstration) :

$$\forall \mathbf{x} \in \mathfrak{R}^p : Err_L(f_G(\mathbf{x})) = noise(\mathbf{x}) + bias^2(\mathbf{x}) + var(\mathbf{x}) \quad \text{E. 58}$$

où :

$$noise(\mathbf{x}) = Err(f_B(\mathbf{x})),$$

désigne le résidu irréductible,

$$bias^2(\mathbf{x}) = \left| f_B(\mathbf{x}) - \frac{1}{N_L} \sum_{G=1}^{N_L} f_G(\mathbf{x}) \right|^2,$$

représente l'écart au carré entre le modèle optimal et l'espérance du modèle choisi. Lorsque le biais est important on dit qu'il y a sous-apprentissage, et enfin

$$var(\mathbf{x}) = \frac{1}{N_L} \sum_{G=1}^{N_L} \left| \left(\frac{1}{N_L} \sum_{G=1}^{N_L} f_G(\mathbf{x}) \right) - f_G(\mathbf{x}) \right|^2,$$

représente la variance du modèle choisi et traduit le degré d'adéquation du modèle avec les bruits des données d'apprentissage. Si la variance est trop importante on parle de sur-apprentissage.

Cas de la classification :

Dans le cas de la classification, une décomposition de l'erreur globale de généralisation existe aussi [82] mais elle est plus complexe que celle qui a été établie dans le cas de la régression. Elle a par ailleurs été plus souvent définie dans le cadre de la classification binaire par rapport aux cas multi-classes. Suite à cette décomposition, le prédicteur optimal devrait minimiser la somme (ou son équivalent dans le cadre de la classification) $bias^2(\mathbf{x}) + var(\mathbf{x})$ afin que son erreur de généralisation soit proche du résidu minimal assuré par le modèle de Bayes. Il est à noter que plus le modèle comprend de paramètres, ce qui traduit sa complexité, plus son biais est faible du fait qu'il permette de s'adapter aux données d'apprentissage. En même temps, plus un modèle est complexe et plus sa variance est importante et ce pour la même raison qui réduit son biais. Il s'agit du compromis Biais-Variance à considérer lors de la conception d'un modèle de prédiction. Néanmoins, nous retiendrons que sous certaines conditions [82], quel que soit le biais d'un classifieur, son erreur de généralisation peut être diminuée lorsque sa variance est réduite. (Figure 45). Les algorithmes de classification adoptés dans ce travail sont optimaux en ce sens qu'ils cherchent à minimiser l'erreur globale soit en réduisant le biais, soit en réduisant la variance et ce de manière à préserver un degré de complexité minimal nécessaire.

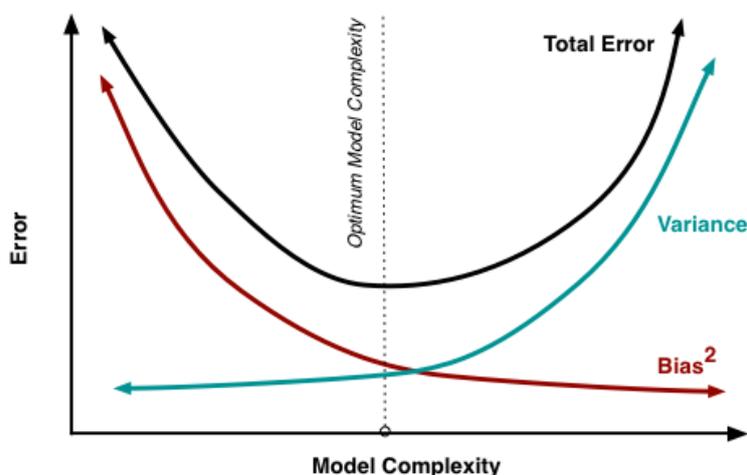


Figure 45 : Compromis Biais-Variance d'un prédicteur en fonction de sa complexité [83]

IV.3.1.3 Méthodes d'évaluation

IV.3.1.3.1 Données d'apprentissage, données test et données de validation

Afin de s'assurer que l'erreur de généralisation obtenue avec un modèle n'est pas trop optimiste du fait d'un éventuel sur-apprentissage, le modèle est évalué en utilisant une part des données non pas pour l'apprentissage mais pour un test. En général, les deux tiers (2/3) des individus labellisés sont utilisés comme données d'apprentissage (Figure 46). Le tiers restant sert pour l'étape de validation croisée. Ce sont les individus tests ou vérité-terrain qui servent à évaluer l'algorithme de classification. Le résultat de leur prédiction est comparé à leur classe-vérité terrain pour avoir une estimation empirique de l'erreur moyenne du classifieur. La sélection des échantillons test parmi les échantillons labellisés se fait aléatoirement de manière à générer deux ensembles de même distribution. Plusieurs tirages peuvent être réalisés, donnant lieu à plusieurs validations. Cette méthode est appelée validation croisée. C'est un processus qui est directement lié à la notion de variance introduite dans la section précédente. Aussi, varier les ensembles d'apprentissage consiste à calculer des modèles différents et à en estimer la variance. Si cette dernière est faible cela signifie que le modèle se généralise bien. Dans le cas contraire, cela signifie que les résultats du modèle sont trop sensibles aux données d'apprentissage et l'algorithme présente une faible capacité de généralisation. L'algorithme final est obtenu en faisant intervenir l'ensemble des individus d'apprentissage et des individus test. Ce modèle est ensuite évalué sur des individus de validation qui ont été mis en place uniquement pour valider le modèle sans jamais intervenir dans le calcul du modèle.

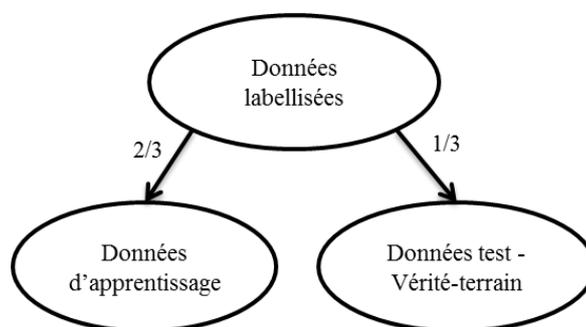


Figure 46 : Répartition des individus labellisés pour les étapes d'apprentissage et de test. Si la validation croisée est réussie, l'ensemble de ces individus sont utilisés pour calculer le modèle final afin de l'évaluer sur des données de validation.

En pratique, l'évaluation de l'erreur d'un classifieur se fait généralement au moyen d'une matrice de confusion $CM \in M(K, K)$ où $K \in \mathbb{N}^*$ est le cardinal des classes. Cette matrice s'écrit :

$$CM = (a_r^m)_{1 \leq r, m \leq K} \quad \text{E. 59}$$

La matrice de confusion se lit comme suivant : Les colonnes d'indices $m \in [1, K]$ représentent les classes vérité-terrain. Les lignes d'indices $r \in [1, K]$ représentent les classes prédites par le classifieur. Si un individu test de classe y_m a été affecté à la classe y_r par le classifieur, le terme a_r^m est incrémenté de 1. Les échantillons bien classés se retrouvent dans l'ensemble $diag(CM) = \{a_r^m / r = m\}$. Les autres termes correspondent à des erreurs de classification.

La précision globale de la classification (Overall Accuracy) est donnée par le ratio entre les individus test bien classés et le nombre total d'individus test classés. La précision relative à la classe y_m est donnée par la fonction 'Relative Accuracy'. Cette statistique est également appelée sensibilité.

$$OA = \frac{tr(CM)}{\sum_{r=1}^K \sum_{m=1}^K a_r^m} \quad \text{E. 60}$$

où tr signifie trace, et

$$RA(m) = \frac{a_m^m}{\sum_{r=1}^K a_r^m} \quad \text{E. 61}$$

IV.3.1.3.2 Statistiques d'évaluation en cas de déséquilibre des distributions

La Figure 47 montre une matrice de confusion dans le cas d'une classification binaire. On considère ainsi une classe « positive : P » et une classe « négative : N ». Il y a 4 possibilités de prédiction données par la figure ci-dessous.

		True class	
		p	n
Hypothesis output	Y	TP (True Positives)	FP (False Positives)
	N	FN (False Negatives)	TN (True Negatives)

Figure 47 : Matrice de confusion pour évaluer la performance d'un classifieur [84]

(1) Si l'on prend un individu de classe positive :

- Sa prédiction est positive → Il s'agit d'un vrai « positif »
- Sa prédiction est négative → Il s'agit d'un faux « négatif »

(2) Maintenant si on considère un individu de classe négative :

- Sa prédiction est négative → Il s'agit d'un vrai « négatif »
- Sa prédiction est positive → Il s'agit d'un faux « positif »

(1)

- **TP (True Positive)**
- **FN (False Negative)**

(2)

- **TN (True Negative)**
- **FP (False Positive)**

Le principe de cette typologie des erreurs peut être étendu au cas multi-classes [85]. Lorsque les classes sont déséquilibrées en termes de distribution et d'échantillons disponibles, ce qui est le cas dans cette étude, la mesure de précision globale est biaisée car elle rend davantage compte de la précision de prédiction de la classe majoritaire. Dans ces situations, d'autres métriques existent pour fournir une évaluation plus complète et moins sensible à la distribution des classes. Nous en citons certaines qui sont largement utilisées dans la littérature en Figure 48.

Measure	Formula	interpretation
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$	
Error rate = 1-Accuracy	$\frac{FP + FN}{TP + TN + FP + FN}$	
Sensitivity (or Recall)	$\frac{TP}{TP + FN}$	Accuracy of positive examples
Specificity	$\frac{TN}{TN + FP}$	Accuracy of Negative examples
Precision	$\frac{TP}{TP + FP}$	

Figure 48 : Métriques usuelles pour l'évaluation de performance d'un classifieur [86]

Ici «Accuracy» correspond à la précision globale. Sa mesure complémentaire est le taux d'erreur (Error rate). Elles rendent toutes les deux compte de la « correction » globale des prédictions obtenues mais elles restent mal adaptées pour les classes non-équitement réparties. La sensibilité et la précision sont quant à elles relatives aux classes. Contrairement aux deux précédentes, ces deux métriques présentent l'avantage d'être insensibles à la distribution des classes. Néanmoins,

l'information qu'elles apportent reste relative à chaque classe et donc insuffisante pour juger globalement de la performance d'un modèle de prédiction. Pour atteindre ce dernier objectif, plusieurs indicateurs issus de la combinaison des métriques de la Figure 48 ont été proposés, mais ces derniers ont souvent été étudiés dans le cadre de la classification binaire [86], [84]. Nous proposons de calculer deux mesures issues de l'extension des méthodes binaires aux cas multi-classes :

- Macro-moyenne géométrique de la sensibilité (MAvG_Sensitivity [87]) définie comme :

$$MAvG_Sensitivity = \sqrt[K]{\prod_{k=1}^K Sensitivity(k)} \quad E. 62$$

- Macro-moyenne géométrique de la précision (MAvG_Precision) définie comme :

$$MAvG_Precision = \sqrt[K]{\prod_{k=1}^K Precision(k)} \quad E. 63$$

Ces deux métriques seront utilisées ultérieurement pour évaluer les performances de classification.

IV.3.2 Algorithmes de classification

Nous nous proposons d'utiliser trois algorithmes de classification jugés performants dans la littérature, bien qu'étant plus complexes que les modèles linéaires ou les K-NN. En référence à la section IV.3.1.2 sur l'erreur de généralisation, nous pensons que des algorithmes « simples » risquent de présenter une grande erreur de généralisation car les frontières entre les classes ont une géométrie complexe du fait d'une grande variabilité au sein de chaque classe. Cela se traduirait par un biais considérable avec des modèles linéaires par exemple. Les prochaines sections présentent succinctement les algorithmes d'apprentissage choisis après consultation de la littérature, à savoir Random Forest (RF), un réseau de neurones artificiels (ANN) et un Séparateur à Vaste Marge (SVM). Les trois algorithmes utilisés sont implémentés dans des bibliothèques Rstudio. Ces dernières permettent de régler les paramètres qui contrôlent chaque algorithme. La théorie détaillée des trois modèles est donnée en ANNEXE 2 : Détails des algorithmes de classification.

IV.3.2.1 Random Forest

L'algorithme Random Forest est une combinaison de plusieurs arbres de décision. Chaque arbre constitue un prédicteur plus ou moins faible. Ici la notion de faiblesse/force traduit notamment la capacité de généralisation d'un modèle de prédiction à de nouvelles données. L'algorithme RF profite du principe du Bagging (Bootstrap and Aggregate) qui revient à combiner plusieurs prédicteurs faibles afin de construire un prédicteur plus fort. Les arbres de décision sont en effet vulnérables au sur-apprentissage car le processus de création des branches est sensible à l'ajout de nouvelles données.

L'algorithme RF utilisé dans ce travail comprend 500 arbres de décisions. Deux tiers des descripteurs retenus par chaque méthode de sélection sont aléatoirement sélectionnés pour la création des arbres.

IV.3.2.2 Réseaux de neurones

La Figure 49 illustre l'architecture d'un réseau de neurones. Son unité est le neurone, représenté par un rond sur la figure. Un réseau de neurones se décompose en plusieurs couches (layers) constituées chacune de plusieurs neurones :

- **Une couche entrée** représentée en vert. Cette couche comporte p neurones qui ne sont rien d'autre que les p variables descriptives d'un individu.
- **Des couches intermédiaires** représentées en orange. Ce sont des couches cachées (hidden layers). Le nombre de neurones qui les composent est quelconque.
- **Une couche de sortie** représentée en bleu. Dans le cas de la classification, elle comporte autant

de neurones que de classes.

Un réseau de neurones est orienté de la couche entrée vers la couche sortie. Deux couches successives sont reliées par un réseau qui connecte les neurones de la première couche aux neurones de la deuxième. Un tel réseau est représenté en gris sur la Figure 49. A part la première et la dernière couche, toutes les autres ont pour paramètres les éléments suivants :

- Un nombre de neurones
- Un biais par neurone
- Un poids par neurone de la couche précédente
- Une fonction d'activation qui est généralement non linéaire.

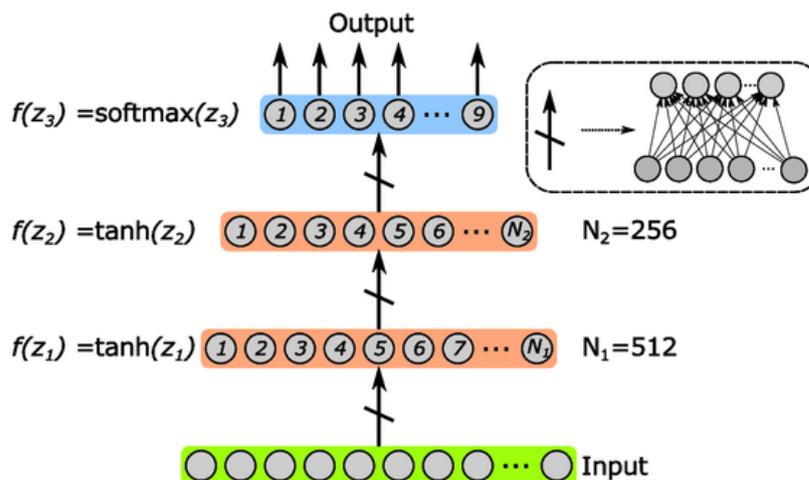


Figure 49 : Exemple d'un réseau de neurone [88]

Le principe d'un réseau de neurone consiste à propager de manière itératives les individus d'apprentissage jusqu'à la couche de sortie. Les résultats de la propagation sont ensuite comparés avec les sorties vraies. Une descente de gradient est utilisée pour corriger les poids de chaque neurone en fonction de l'erreur de prédiction jusqu'à convergence du modèle vers une configuration de poids optimale.

Dans ce travail, seule une couche cachée est utilisée. Sa fonction d'activation associée est la fonction softmax (voir annexe 2). Le nombre de neurones de la couche cachée est de 20. Ce réseau de neurone est assez simple et peut probablement être amélioré en multipliant les couches cachées. La simplicité du modèle utilisé devra être prise en compte dans l'évaluation des résultats de la reconnaissance.

IV.3.2.3 Séparateurs à Vaste Marge

Les séparateurs à vaste marge sont des modèles géométriques cherchant à trouver les hyperplans qui maximisent la distance entre des individus de classes différentes dans l'espace des descripteurs. La recherche de l'hyperplan optimal se fait de manière analytique dans les cas linéairement séparables. La distance des individus d'apprentissage les plus proches de l'hyperplan (vecteurs supports) est appelée marge. Lorsque certains échantillons rendent impossible l'existence d'un hyperplan optimal (une marge dure), un ensemble de paramètres dits variables ressorts sont introduits permettant ainsi de classer incorrectement certains individus d'apprentissage. Enfin, dans les cas non linéaires, les noyaux kernels sont utilisés afin d'exprimer les individus d'apprentissage dans un espace de dimension supérieure. Cela permet notamment de disperser davantage les individus et de se ramener au cas de la séparabilité linéaire.

Les paramètres du modèle SVM ont été laissés par défaut tels qu'implémenté dans la librairie e1071 [89] car les résultats obtenus avec ce paramétrage sont satisfaisants.

IV.3.3 Algorithmes de sélection des descripteurs pertinents

Les méthodes de réduction dimensionnelle sont préconisées dans les problèmes de classification. Elles permettent de prévenir le sur-apprentissage, d'augmenter la rapidité de calcul et d'assurer une meilleure généralisation de l'algorithme de classification. Ces méthodes peuvent être décomposées en deux catégories. Les méthodes d'extraction et les méthodes de sélection. L'objectif des méthodes d'extraction consiste en la représentation des données dans un nouvel espace de manière à absorber la majeure part d'information et à l'exprimer suivant un nombre d'axes réduit. Parmi ces méthodes on peut citer l'ACP¹⁶ (PCA), la LDA¹⁷, ou encore la CCA¹⁸. Les méthodes de sélection quant à elles ne transforment pas les données mais elles n'en retiennent que celles qui sont pertinentes. Elles ont donc l'avantage d'être interprétables physiquement. Plusieurs définitions existent pour la notion de pertinence d'un descripteur [90]. Toutefois, c'est une notion qui reste relative. Une des définitions est la suivante :

«Un descripteur \mathbf{x}^j est pertinent relativement à la variable catégorielle y s'il existe une paire d'individus ($\mathbf{x}_i, \mathbf{x}_{k \neq i}$) à valeurs différentes suivant \mathbf{x}^j , à valeurs égales suivant les autres variables descriptives $\mathbf{x}^{l \neq j}$, et étant affectées à deux classes différentes.» [90].

Cela signifie donc que la variable de sortie y est sensible au descripteur \mathbf{x}^j . Cette sensibilité traduit notamment une dépendance des classes à la variable \mathbf{x}^j . Les méthodes de réduction dimensionnelle cherchent toutes à trouver les descripteurs permettant de concentrer une grande quantité d'information en peu de variables ainsi que d'en dégager une certaine structure. Par conséquent, nous consacrons la prochaine section à la notion d'inertie qui est exploitée dans les méthodes de sélection adoptées dans ce travail.

IV.3.3.1 Définitions

IV.3.3.1.1 Inertie totale d'un nuage de points

Considérons un nuage de n points (individus) répartis en K classes. L'ensemble des individus affectés à la classe y_k est noté C_k . L'inertie du nuage de points $\{\mathbf{x}_i \in C_k\}$ s'écrit :

$$I_k = \sum_{i=1}^{n_k} d^2(\mathbf{x}_i, \mathbf{g}_k) \quad \text{E. 64}$$

Où \mathbf{g}_k est le centre de gravité de C_k , n_k son cardinal et d l'opérateur « distance ». Le centre de gravité de toutes les classes confondues est noté \mathbf{g} . Le nombre d'individus de toutes les classes confondues est :

$$n = \sum_{k=1}^K n_k \quad \text{E. 65}$$

Il est clair d'après cette définition que l'inertie d'un nuage d'individus traduit la dispersion de ce dernier autour de son centre de gravité. Plus l'inertie est grande, plus le nuage est dispersé autour de son centre.

IV.3.3.1.2 Inertie d'un nuage de points par rapport à un axe

L'inertie d'un nuage de points par rapport à un axe Δ est défini par :

$$I_{\Delta} = \sum_{i=1}^n d^2(\mathbf{x}_i, \Delta) \quad \text{E. 66}$$

où $d^2(\mathbf{x}_i, \Delta)$ est le carré de la distance entre l'individu \mathbf{x}_i et sa projection orthogonale sur l'axe Δ . De même que l'inertie totale indique la dispersion du nuage autour du centre de gravité, l'inertie par

¹⁶ Analyse en Composantes Principales (Principal Component Analysis)

¹⁷ Linear Discriminant Analysis

¹⁸ Canonical Correlation Analysis

rapport à un axe mesure la dispersion autour de cet axe. Plus cette inertie est grande, plus le nuage est éloigné (en termes de distance de projection d'un point sur une droite) de l'axe en question.

IV.3.3.1.3 Inerties intra-classe et inter-classe

L'inertie du nuage d'individus appartenant à la même classe est appelée inertie intra-classe. Son inertie en considérant toutes les classes s'appelle inertie inter-classe.

Inertie intra-classe :

$$I_W = \sum_{k=1}^K \omega_k I_k \quad \text{E. 67}$$

Inertie inter-classe :

$$I_B = \sum_{k=1}^K \omega_k d^2(\mathbf{g}_k, \mathbf{g}) \quad \text{E. 68}$$

Le coefficient ω_k correspond au poids affecté à la classe k . Si tous les individus ont le même poids, ce qui est le cas dans ce travail, alors :

$$\omega_k = \frac{\text{Card}(C_k)}{n} \quad \text{E. 69}$$

Dans ce cas les deux inerties sont proportionnelles à des covariances, que nous appelons également covariance intra-classe et covariance inter-classe. Pour illustrer la notion d'inertie, prenons l'exemple de deux nuages de points contenant chacun deux classes différentes, une bleue et une rouge.



Figure 50 : Ces deux nuages de points correspondent à la visualisation de deux classes indiquées par deux couleurs différentes. L'axe horizontal correspond à un attribut 1 et l'axe vertical à un attribut 2. A gauche, les deux classes sont bien séparées dans l'espace des attributs. A droite les deux classes se recouvrent [91].

A gauche de la Figure 50, les deux classes se séparent bien dans l'espace des attributs. On remarque que chaque classe présente une faible dispersion, ce qui traduit une faible inertie intra-classe. Au contraire, les deux nuages pris ensemble présentent une forte dispersion, et ont donc une forte inertie inter-classe. La même analyse peut être menée sur la partie droite de la figure où les classes sont mal séparées. L'inertie inter-classe est forte et l'inertie intra-classe est faible. En effet, pour optimiser la séparation des classes, il faut que les descripteurs des échantillons minimisent la covariance intra-classe et maximisent la covariance inter-classe.

IV.3.3.2 Algorithmes de sélection des descripteurs pertinents

Les problèmes de sélection des descripteurs sont des problèmes d'optimisation où l'on cherche à fournir une sélection de descripteurs optimaux au regard d'un objectif donné. Cela induit donc des critères d'optimisation qui peuvent varier selon les méthodes de sélection. Ces dernières varient également en fonction des descripteurs. La Figure 51 fournit un bref aperçu des 3 grandes familles de sélection selon la nature des descripteurs considérés. En premier lieu, on considère les descripteurs indépendants les uns des autres, sans structure ni liens internes préalablement connus. Il s'agit des « Flat Features ». En deuxième lieu, les descripteurs changent en temps réel : il en arrive et il en part. Leur nombre varie dans le temps. Enfin, en troisième lieu, les descripteurs sont considérés au sein d'un ensemble structuré et donc avec des liens et éventuellement une hiérarchie [92]. Dans ce travail, nous ne supposons pas de lien particulier entre les descripteurs et leur nombre est fixe dans le temps. Cela nous amène à explorer les trois méthodes de sélection relatives aux « Flat Features » conformément à la Figure 51.

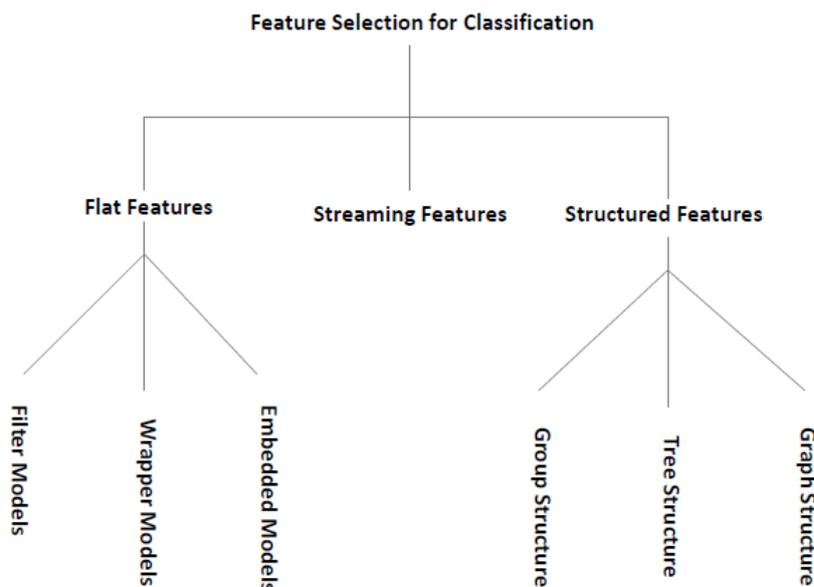


Figure 51 : Groupes de méthodes pour la sélection des descripteurs [92]

La première catégorie apparente les méthodes dites « Filter models ». Ces modèles sont construits indépendamment des algorithmes d'apprentissage. L'optimisation y est réalisée en exploitant des statistiques sur les données. La 2^{ème} catégorie comprend les « Wrapper models » qui réalisent la sélection des descripteurs jugés pertinents relativement à un classifieur donné. La fonction d'optimisation de ces méthodes prend en compte l'algorithme d'apprentissage, sans en connaître la nature ni les paramètres [93]. Un moyen simple de prendre en compte l'algorithme d'apprentissage passe par un calcul de matrice de confusion et éventuellement par une validation croisée. Enfin, on distingue les « Embedded models » qui sont des modèles de sélection intrinsèquement liés aux algorithmes d'apprentissage. C'est-à-dire que les étapes de sélection et d'apprentissage ne peuvent être séparées [93]. La fonction d'optimisation de ces modèles prend comme critères à la fois les paramètres du classifieur et les descripteurs en entrée.

La première famille regroupe des méthodes plutôt intuitives et peu coûteuses en temps de calcul. La deuxième catégorie permet d'adapter les résultats de la sélection au type de classifieur déployé, mais elle présente un coût de calcul considérable ainsi qu'un risque de sur-apprentissage plus élevé que les autres catégories de méthodes [92]. Enfin, la dernière catégorie a les avantages des deux précédentes, à savoir un faible coût de calcul et une adaptation à l'algorithme d'apprentissage, tout en présentant une plus grande robustesse car elle prévient le sur-apprentissage [92].

Dans ce travail, nous employons trois méthodes de sélection différentes dans la catégorie des « Filter models » expliquées dans les sections suivantes.

IV.3.3.2.1 Sélection par Analyse en Composantes Principales (PCA)

La PCA est à la fois une méthode d'extraction et de sélection. Elle permet de passer d'un premier espace de représentation, où les variables sont potentiellement corrélées, à un espace de moindre dimension où les variables sont indépendantes et permettent d'exprimer les données initiales sans engendrer une grande perte d'information. La quantité d'information est approchée par la variance retenue par les axes de la PCA. Le calcul des axes d'une PCA se fait de manière rigoureuse à partir de la matrice de covariance des données [94]. Ces axes ne sont rien d'autre qu'une combinaison linéaire des descripteurs initiaux.

D'un point de vue géométrique, la PCA cherche les axes mettant en avant une structure au sein des données. Par exemple, si le nuage présente la forme d'une ellipse, les axes de la PCA correspondent alors aux grand et petit axes de l'ellipse. Ces axes passent tous par le centre de gravité du nuage (Figure 52). Pour en trouver l'orientation, la PCA cherche les directions par rapport auxquelles l'inertie du nuage d'individus est minimale (IV.3.3.1.2). Il s'agit foncièrement d'un problème d'optimisation. Le premier axe (première solution) est donné par le vecteur propre associé à la plus

grande valeur propre de la matrice de covariance des données. La variance des données projetées suivant cet axe est maximale (1^{er} axe de la Figure 53). De même, le deuxième axe lui est orthogonal et est donné par le vecteur propre associé à la deuxième plus grande valeur propre, ainsi de suite. Les premiers axes d'une PCA sont retenus car ils expliquent la majeure part de variance totale.

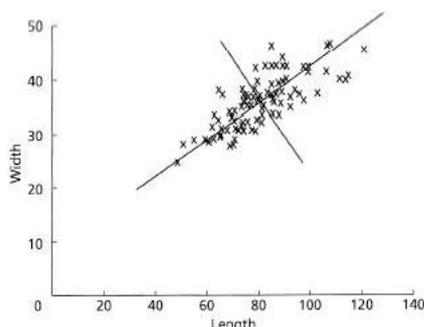


Figure 52 : Nuage d'individus selon deux descripteurs (Length, Width) et axes de la PCA [95]

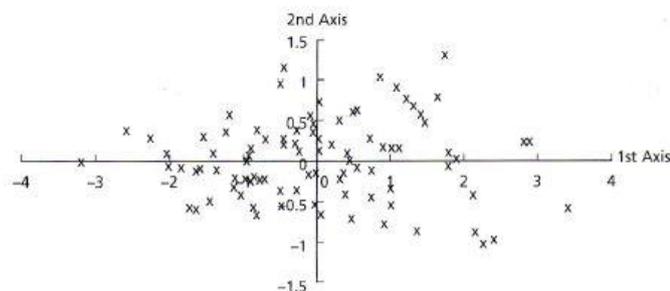


Figure 53 : Nuage d'individus exprimés selon la nouvelle base donnée par les deux axes de la PCA [95]

Puisque les axes d'une PCA sont des combinaisons linéaires des descripteurs initiaux, la PCA est également utilisée comme méthode de sélection [96], [97]. Chacun des axes de la PCA est un vecteur propre de la matrice de covariance des données. Il est obtenu par la combinaison linéaire suivante :

$$PC_i = \lambda_1^i \mathbf{x}^1 + \lambda_2^i \mathbf{x}^2 + \dots + \lambda_p^i \mathbf{x}^p \quad \text{E. 70}$$

où $(\lambda_1, \lambda_2, \dots, \lambda_p)$ sont les valeurs propres associées au vecteur propre PC_i . Ces valeurs sont exploitées dans la sélection des descripteurs pertinents. En effet, un descripteur associé à un grand coefficient a une forte contribution à l'axe en question. Par conséquent, si ce dernier retient une grande part de la variance totale, cela signifie que le descripteur contribue aussi considérablement à la variance totale au sein des données. Si tous les coefficients ont le même ordre de grandeur, la sélection n'est plus judicieuse car tous les descripteurs contribuent équitablement aux axes considérés. Dans cette analyse, la pertinence des descripteurs est pensée relativement à la variance expliquée par les descripteurs. Elle ne tient donc pas compte des classes en considérant le nuage de points dans sa globalité. La PCA sert donc à éliminer les variables pour lesquels la variance est faible, autrement dit, les descripteurs qui varient très peu bien que les classes soient différentes.

IV.3.3.2.2 Sélection par calcul du Score de Fisher (SF)

Le calcul du Score de Fisher est également utilisé comme méthode de sélection [98]. Ce score est donné par le ratio entre l'inertie inter-classe et l'inertie intra-classe (IV.3.3.1.3).

$$FS(X) = \frac{I_B(X)}{I_W(X)} \quad \text{E. 71}$$

Contrairement à l'ACP qui examine les données en un seul lot, le SF permet de tenir compte des classes dans le calcul de variance en séparant inertie inter-classe et inertie intra-classe. Le nombre de descripteurs retenus est déterminé selon une règle heuristique comme un seuillage ou en imposant un nombre minimal de descripteurs.

IV.3.3.2.3 Sélection par calcul de l'information mutuelle

L'information mutuelle de deux variables aléatoires discrètes X et Y est un estimateur de la quantité d'information communiquée par la première variable sur la seconde [99]. En d'autres termes, l'information mutuelle est une mesure de la dépendance entre deux variables. Elle est donnée par la formule :

$$I(X, Y) = \sum_{i=1}^n \sum_{j=1}^n p(X(i), Y(j)) \log_{10} \frac{p(X(i), Y(j))}{p(X(i))p(Y(j))} \quad \text{E. 72}$$

où $X(i)$ est la $i^{\text{ème}}$ réalisation de X et $p(X(i))$ sa probabilité d'occurrence, $Y(j)$ la $j^{\text{ème}}$ réalisation

de Y et $p(Y(j))$ sa probabilité d'occurrence, enfin $p(X(i), Y(j))$ est la probabilité d'occurrence du couple $[X(i), Y(j)]$.

Aussi, si les variables X et Y sont indépendantes, l'information mutuelle est nulle. Au contraire, plus elles sont dépendantes, plus l'information mutuelle est grande. Par conséquent, le problème de sélection grâce à l'information mutuelle consiste à sélectionner les m descripteurs ayant les m plus grandes valeurs d'information mutuelle. Si X est la variable « descripteur » et Y la variable « classe », alors le meilleur descripteur en termes d'information mutuelle est donné par :

$$X^{opt} = \arg \max_{idx} I(X^{idx}, Y) \quad \text{E. 73}$$

IV.4 Méthodologie proposée pour la mise à jour de position grâce à des POIs

IV.4.1 Approche proposée

Cette section vise à clarifier notre contribution en matière d'aide à la localisation au moyen d'une reconnaissance de mouvement. Elle concerne deux axes d'améliorations. Le premier consiste à reconsidérer la problématique de la transition indoor-outdoor afin de mieux la détecter. Le second vise à fournir une définition technique et standardisée de la notion de points d'intérêt et à fournir un algorithme de reconnaissance pour les détecter. L'apport global de cette approche est une mise à jour de position fréquente par détection de POIs qui sont généralisables à tout environnement et détectables grâce aux mesures des capteurs embarqués dans les smartphones.

IV.4.1.1 Détection de la transition indoor-outdoor

La section IV.2 a permis de soulever plusieurs problématiques liées à la détection de la transition IO. Entre autres, il existe plusieurs définitions de l'indoor et de l'outdoor en fonction des technologies considérées. Une des technologies les plus utilisées est le GNSS mais elle requiert d'introduire au moins une troisième classe d'environnement autre que l'indoor ou l'outdoor. L'introduction d'une troisième classe (ex. semi-outdoor) implique certaines situations où l'intérieur d'un bâtiment puisse ne pas être considéré comme un espace indoor, ce qui implique une latence temporelle qui ne répond pas au besoin de détecter plus ou moins instantanément les moments d'accès aux bâtiments afin de mettre à jour la position du piéton. L'utilisation du GNSS est donc écartée de notre approche de détection IO, bien qu'elle soit utilisée ailleurs dans le calcul de position. L'état de l'art montre aussi que la plupart des méthodes de reconnaissances IO sont sensibles aux variations environnementales, avec une seule étude proposant d'exploiter uniquement l'information des activités de l'utilisateur et de la mettre en correspondance avec l'environnement indoor ou outdoor, toujours avec un risque que l'hypothèse du lien supposé entre l'activité et l'environnement soit fausse [75]. Le champ des recherches dédiées à la détection IO grâce aux capteurs inertiels, magnétiques et barométriques reste assez restreint. Notons que dans notre étude de l'état de l'art le signal du gyromètre ou de l'accéléromètre n'ont jamais été exploités directement pour la détection IO mais seulement pour reconnaître l'activité du piéton, et une seule étude a démontré la contribution du baromètre à la détection des ouvertures de portes d'accès aux bâtiments, toutefois avec une collecte de signal qui ne convient pas au cadre de la navigation (acquisition du signal en mode statique pour détecter les ouvertures de portes). Par conséquent, les descripteurs les plus pertinents pour la détection IO avec les capteurs usuels de la navigation ne sont pas suffisamment documentés dans l'état de l'art. Enfin, la plupart des études évaluent les modèles obtenus sur des données test, issues des mêmes environnements où les données ont été collectées pour l'apprentissage. Ces mêmes modèles présentent des performances moins bonnes lorsqu'ils sont appliqués dans de nouveaux environnements. Prenant en compte ces différentes difficultés, cette étude propose la démarche suivante :

- Revenir à la définition originale de l'indoor et de l'outdoor. Le premier ensemble comprend toute infrastructure couverte par un toit et délimitée par des façades, quelle que soit son exposition au soleil et aux satellites GNSS. L'outdoor est le complément spatial de l'indoor. En d'autres termes, les espaces semi-outdoor sont ici considérés comme outdoor, et les espaces light-indoor correspondent à de l'indoor. La frontière entre les deux espaces est donnée la porte d'accès au bâtiment.

- La frontière entre les deux espaces étant définie, il s'agit de s'affranchir du besoin de reconnaître l'indoor et l'outdoor et de s'intéresser directement à la reconnaissance de la transition entre les deux espaces, c'est-à-dire les portes d'accès comme proposé dans l'étude [80] qui a exploité le signal du baromètre.
- Mettre en place un protocole d'acquisition qui s'approche des cas réels de navigation : Ouvertures des portes pendant la marche, intégration de plusieurs types de portes, participation de plusieurs sujets, collecte du signal dans plusieurs bâtiments.
- Mettre en place une méthodologie de sélection des descripteurs les plus pertinents pour la détection IO mais aussi pour d'autres classes de mouvement qui définissent les POIs.
- Réduire la latence temporelle de détection au minimum nécessaire.
- Evaluer la méthode sur des données acquises par des sujets nouveaux dans des environnements nouveaux.

IV.4.1.2 Standardisation des points d'intérêt (POIs)

L'état de l'art sur les méthodes d'exploitation de la carte pour améliorer la localisation montre que la reconnaissance contextuelle permet souvent d'adapter les modèles de navigation PDR. Notre objectif est différent car il consiste à fournir une Base de données de POIs qui fournissent des mesures de position à intervalles de temps courts pour limiter les effets de dérive. Il s'agit d'une mesure ponctuelle et commune à divers types d'environnements sans être impactée par l'architecture spécifique à chaque bâtiment. En ce sens, un POI est défini par sa position sur la carte et par son type. Il représente une région réduite de l'espace¹⁹ qui est typique à un ensemble de mouvements piéton. Le mouvement piéton peut-être reconstitué par une séquence de mouvement, qui est une suite de classes de mouvement. Certaines séquences et certaines classes permettent de définir des POI (IV.4.2). Nous appelons régime permanent la période correspondant à la réalisation d'une classe de mouvement. Le moment qui sépare les régimes permanents de deux classes distinctes est appelé transition. La typologie des POI est essentiellement déterminée par la reconnaissance soit d'un régime permanent, soit d'une transition. Ces points d'intérêt sont standards en termes de généralisation à différents environnements, en termes de pérennité (contrairement aux balises WIFI par exemple) mais aussi en termes de détectabilité car cette dernière requiert uniquement le signal qui est délivré par les capteurs embarqués.

IV.4.1.3 Démarche générique proposée

La méthodologie exposée dans ce chapitre est décrite dans la Figure 54. Une fois que la typologie des POIs est définie et la nomenclature de la classification établie (section IV.4.2), une campagne d'acquisition est lancée afin de collecter les signaux dans les environnements d'intérêt pour la classification (section IV.4.3). Une sélection des signaux intéressants est réalisée après la collecte des données. Ensuite, plusieurs descripteurs sont calculés sur la base de chaque signal retenu. Trois méthodes de sélection sont déployées afin de déterminer les descripteurs les plus pertinents vis-à-vis des sorties de la classification. Il s'agit de l'information mutuelle, du score de Fisher (FS) et d'une analyse en composantes principales (PCA). Les descripteurs retenus par chaque méthode sont introduits en entrée de trois algorithmes d'apprentissage principaux : Réseau de neurones artificiel (ANN), Séparateur à Marge (SVM) et Random Forest (RF). Les résultats sont évalués dans le chapitre VI.1.2, d'abord sur des données test puis sur des données de validation. Ces dernières sont issues d'environnements qui n'ont pas contribué à l'étape d'apprentissage (nouveaux bâtiments et sujets pour les modèles de reconnaissance). Grâce au choix des algorithmes optimaux pour la reconnaissance de mouvement et la détection de POI, un plan de mise à jour de position par détection de POIs est intégré au filtre qui réalise le calcul de position (section V.3.5). Ce plan est mis en œuvre sur des données expérimentales pour évaluer les améliorations de positions rendues possibles. Ce dernier aspect est traité plus loin dans la section VI.2.2.1.1.

¹⁹ Une région réduite est approximée par un ponctuel. Ceci est important car le terme point d'intérêt est utilisé dans la littérature pour désigner des endroits dont l'étendue spatiale est importante. Ce sont des POI relatifs aux intérêts de l'utilisateur comme les espaces de divertissement et non pas aux besoins de la localisation.

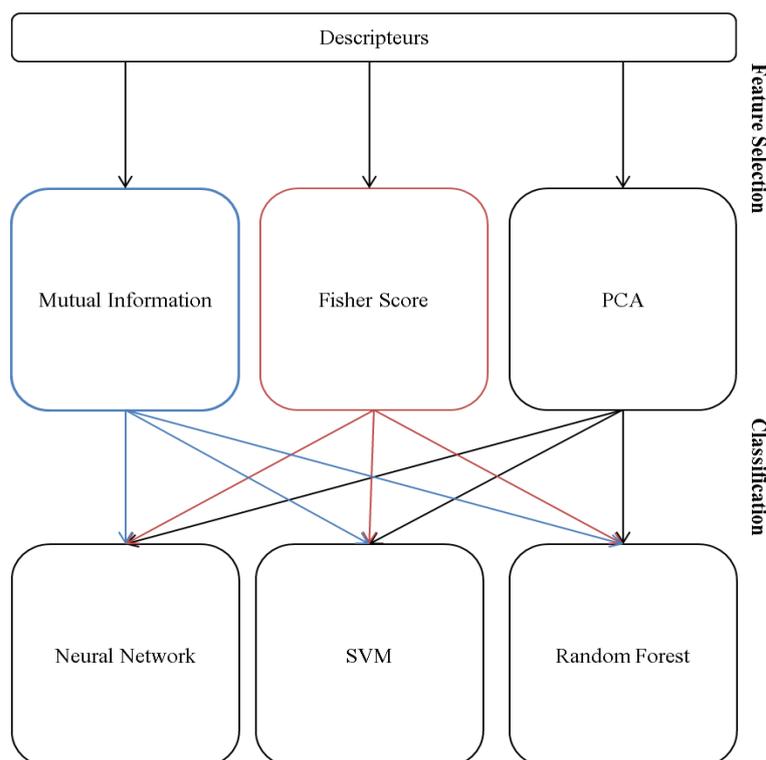


Figure 54 : Trame de traitement pour l'apprentissage supervisé

IV.4.2 Typologie des POIs à partir d'une classification de mouvement

IV.4.2.1 Définition des POIs

Les POI matérialisent principalement des changements de direction, horizontale ou verticale, induits par la géométrie de l'espace. La troisième catégorie de POI correspond aux portes d'accès aux bâtiments. Par la construction des graphes de navigation, les POI se trouvent au voisinage de nœuds. La mise en place d'une BDD de POI passe par une typologie qui découle des classes ou séquences de mouvement usuelles qu'un piéton réalise au cours de son déplacement. Cette typologie se présente comme suivant :

1. **Les ascenseurs** : Le POI ascenseur correspond au centre de la cage de l'ascenseur. La mise à jour de position planimétrique par détection d'ascenseur est conforme à l'état de l'art [100]. Cette position reste inchangée durant toute la durée de la montée ou la descente de l'ascenseur.
2. **Les coins de bâtiment** : Les coins matérialisent le changement de direction induit par la géométrie des couloirs. Ils sont modélisés par des ponctuels et peuvent figurer sur le graphe de navigation comme nœuds, mais cela n'est pas nécessaire. Ils peuvent être exploités pour observer la variation de cap [68]. Dans ce travail, les coins de bâtiments fournissent une mesure de position.
3. **Le hauts/bas d'escaliers** : L'intégration des escaliers au processus de mise à jour de position nécessite une séparation des hauts et des bas d'escaliers. Cela diffère des méthodes existantes qui exploitent la détection des escaliers pour diverses calibrations, notamment de distance. Ces méthodes supposent par ailleurs une connaissance des caractéristiques physiques et géométriques de la cage d'escaliers (largeur, hauteur de marche, pente). De même, de telles calibrations ne sont efficaces que si le cap de marche est également corrigé. Or cette correction est parfois difficile à obtenir, notamment si elle est fournie par la carte, par exemple dans le cas d'un escalier tournant. La position planimétrique d'un POI correspondant à un haut ou un bas d'escalier est ici donnée par le barycentre géométrique de la dernière ou première marche. Le but d'une mise à jour de position par détection de haut/bas d'escalier est de s'affranchir du besoin de la connaissance de l'architecture de la cage d'escaliers ainsi que la détection d'un changement de niveau altimétrique (pallier,

étage ou niveau en extérieur).

4. **Accès aux bâtiments** : Il s'agit des portes d'accès aux bâtiments. Cela comprend notamment des portes battantes et des portes glissantes. Sur la carte, toutes les portes sont confondues sous un même type de POI donné par le centre géométrique du seuil de chaque porte.

IV.4.2.2 Nomenclature de la classification

La typologie des POI est liée à un ensemble de classes de mouvement présentées en Figure 56. Les notations sont données par les tableaux suivants :

Classe de mouvement	Notation
Changement de direction	Co
Montée d'escaliers	US
Descente d'escaliers	DS
Marche en ligne droite	NW
Statique	Static
Montée d'ascenseur	EU
Descente d'ascenseur	ED
Entrée dans un bâtiment	Do_Entry
Sortie d'un bâtiment	Do_Exit

Table 4 : Notation des classes de mouvement

POI	Notation
Coin de bâtiment	Co
Bas d'escaliers	DS
Haut d'escaliers	US
Ascenseur (Elevator)	E
Porte d'accès	Do

Table 5 : Notation des POI

IV.4.2.3 Schéma simplifié du lien entre les classes de mouvement et les POIs

Un schéma simplifié est d'abord mis en œuvre afin de démontrer la faisabilité d'une mise à jour de position par détection de POIs. Ce schéma est simplifié pour plusieurs raisons. D'abord, les phases statiques sont préalablement connues car elles interviennent en amont de la détection de POIs pour la détection de pas [18]. Ensuite, la transition indoor-outdoor se résume à la séquence : Marche Normale – Phase statique (de courte durée déterminée empiriquement) – Marche Normale. Cette simplification est possible car seules les portes battantes sont prises en compte. Aussi, la nomenclature de la classification est réduite au schéma de la Figure 55. Enfin, le modèle de classification est calculé sur des données collectées par un seul sujet dans un seul type d'environnement indoor. La classification est réalisée avec un algorithme K-NN et les descripteurs sont choisis par interprétation physique du signal (i.e. sans processus de sélection). Une description détaillée de ce modèle est fournie dans [101]. Nous souhaitons abréger les développements de ce modèle dans ce document et nous focaliser sur le schéma évolué de la détection de POI correspondant à la nomenclature de la Table 4.

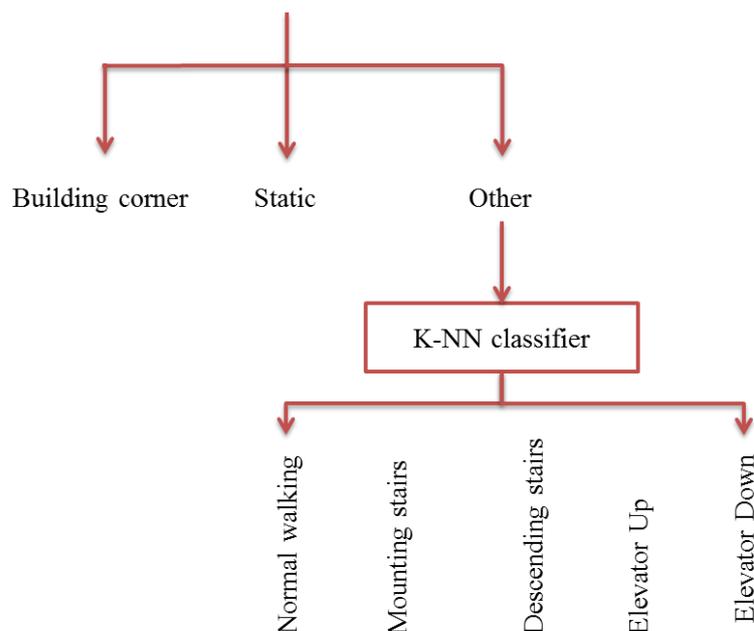


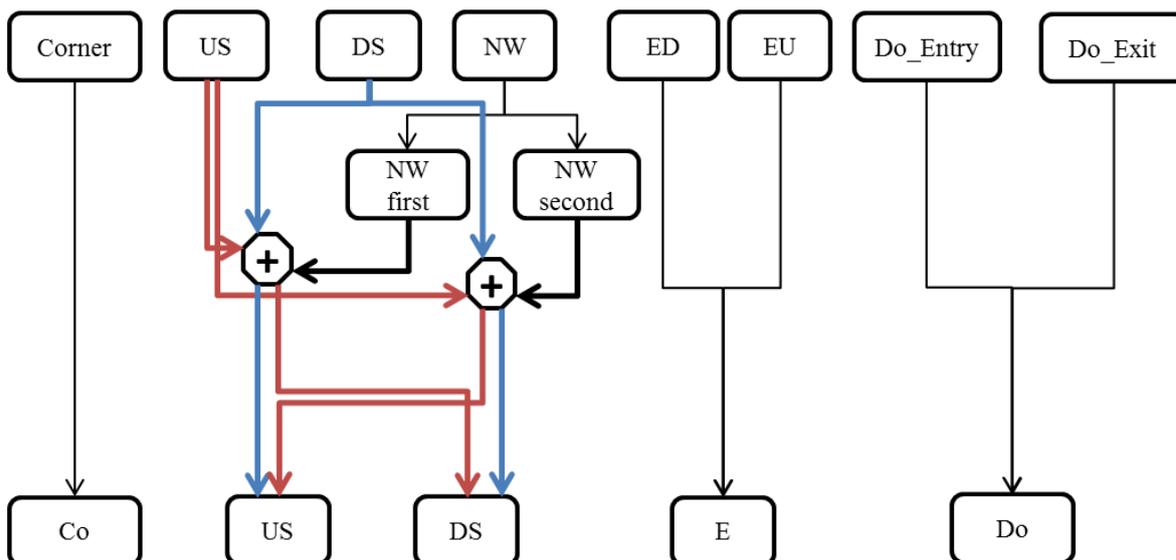
Figure 55 : Schéma de classification simplifié

IV.4.2.4 Schéma évolué du lien entre les classes de mouvement et les POIs

Le schéma évolué diffère du schéma simplifié de par plusieurs critères. Il est décrit par la Figure 56. En particulier, la transition indoor-outdoor intègre plusieurs types de portes (glissantes, battantes, etc.). Elle n'est plus définie par une séquence de mouvement mais elle constitue en soi une classe et un POI. En effet, les entrées dans les bâtiments et les sorties des bâtiments sont deux classes différentes (Do_Entry, Do_Exit). La base de données des POIs est plus conséquente en nombre et en variété des environnements pris en compte. Elle intègre également des données collectées par plusieurs utilisateurs. Ces choix permettent une modélisation plus réaliste des POIs. Ils entraînent par ailleurs un besoin d'adaptation du modèle de détection, requérant notamment une sélection pertinente des descripteurs choisis et l'emploi de modèles de classification plus complexes que l'algorithme K-NN.

Remarques sur la lecture de la Figure 56 :

Lorsque la classe de mouvement (haut de la Figure 56) fournit directement le type de POI (en bas de la figure), cela est traduit par une flèche fine reliant la classe au POI. Dans le cas statique, aucune mise à jour n'est appliquée. Lorsque le POI est donné par une séquence de mouvement, cela est traduit par un signe « + » signifiant la somme de deux classes. Les séquences de mouvement comprennent toutes la classe NW. Aussi, si cette classe est réalisée en premier lieu, elle est notée « NW first », si elle est réalisée en second lieu, elle est notée « NW second ». La figure est accompagnée d'une légende qui en facilite la lecture.



Légende:

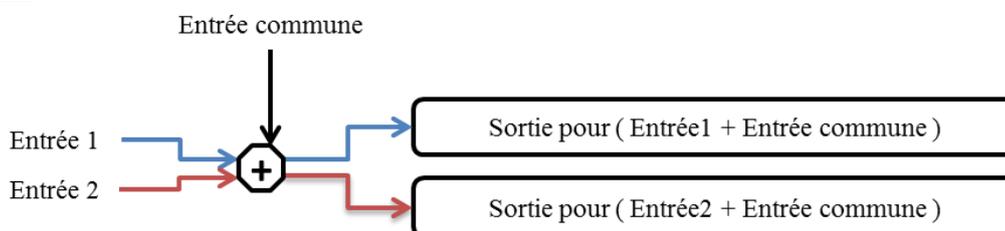


Figure 56 : Typologie des POI en fonction des classes de mouvement

IV.4.3 Collecte des signaux

IV.4.3.1 Matériel

Le capteur utilisé pour collecter les données est une centrale inertielle et magnétique appelée ULISS (Ubiquitous Localization unit with Inertial Sensors and Satellites). Elle comprend une IMMU à 9 degrés de liberté, avec un accéléromètre, un gyromètre et un magnétomètre tri-axes. Elle comprend également un capteur de pression ainsi qu'un récepteur et une antenne GNSS à haute sensibilité. Les signaux sont tous délivrés à une fréquence de 200 Hz, à part les signaux GNSS qui sont fournis à une fréquence de 5 Hz. Toutes les mesures sont horodatées en temps GPS. Le signal GNSS n'est pas exploité pour la classification. C'est un capteur qui a été conçu pour mener des recherches sur la navigation piétonne. Il permet notamment de s'affranchir des problèmes de synchronisation temporelle entre les différents capteurs et le récepteur GNSS, ce qui n'est pas le cas pour les smartphones. Il permet aussi de s'affranchir des contraintes de batterie qui agissent sur la fréquence d'échantillonnage des signaux dans un smartphone. Cependant, il contient des capteurs MEMS de gamme « consommateurs », la même gamme de capteurs que ceux qui sont intégrés dans les smartphones.



Figure 57 : Centrale inertielle et magnétique ULISS

IV.4.3.2 Scénarios d'acquisition pour construire une base de données d'apprentissage

IV.4.3.2.1 Collecte de signal pour le modèle simplifié

Dans le cadre du modèle simplifié, les acquisitions sont réalisées de manière à calculer un modèle individuel de reconnaissance. Le signal est collecté par un seul sujet dans un seul bâtiment avec un seul type de portes battantes. Ce modèle est caractérisé par une petite base de données, une faible variabilité environnementale et une interprétabilité physique du signal assez aisée. Les résultats de la reconnaissance avec ce modèle [101] ne sont pas repris dans ce mémoire. En revanche, les résultats de la détection en ligne sont fournis à titre indicatif à la section VI.2.2.1. Notons que toutes les classes ont ici la même longueur temporelle, ce qui facilite le processus de segmentation du signal et de détection des POI une fois que la classification de mouvement est réalisée. Pour le modèle évolué, nous proposons un schéma de détection prenant en compte la variabilité temporelle des longueurs de fenêtres à la section (IV.4.6). L'innovation de ce premier travail est la démonstration de l'apport de la reconnaissance de mouvement pour rattraper des erreurs de types divers en environnements difficiles (absence de GNSS ou erreurs dans le graphe de navigation).

La suite de ce chapitre ne traite plus que de la démarche mise en place pour la détection de POI selon le schéma évolué.

IV.4.3.2.2 Collecte de signal élargie à plusieurs sujets et plusieurs bâtiments

Les acquisitions ont été menées par huit personnes (4 femmes et 4 hommes) qui ne présentent pas de difficulté motrice particulière. L'ensemble des acquisitions ont eu lieu sur le site de l'IFSTTAR Nantes (Figure 58). Elles ont été réalisées en extérieur mais aussi dans six bâtiments différents donnés par les symboles bleus sur la Figure 58. Le capteur a été utilisé dans un mode Texting afin de s'affranchir du besoin de connaître son attitude²⁰. Les signaux ont été collectés pour différents scénarios listés ci-dessous :

- **11 portes d'accès aux bâtiments**

Sur les 11 portes, 10 étaient des portes battantes et une porte glissante. Nous avons donc multiplié les acquisitions pour cette dernière afin d'équilibrer les types de portes.

- **10 escaliers différents**

La moitié des escaliers étaient situés au sein des bâtiments et l'autre moitié à l'extérieur. Leurs différences concernent notamment les pentes, les hauteurs de marches ainsi que la taille des marches.

- **8 coins de couloirs**

Les coins de couloirs sont sensibles au mouvement piéton plutôt qu'à l'environnement. Aussi les acquisitions ont eu lieu dans le même bâtiment dans deux étages différents.

- **2 ascenseurs de deux bâtiments**

- **3 scenarios de marche libre en extérieur**

IV.4.3.2.3 Occurrence des classes de mouvement

Nous avons opté pour des acquisitions de courte durée afin de marquer le début et la fin de chaque régime permanent. Chaque participant a réalisé les actions suivantes :

- Faire plusieurs (En moyenne 4 répétitions) montées et descentes de chaque escalier. Varier la vitesse de déplacement pour chacune des répétitions.
- Faire plusieurs entrées-sorties pour chacune des portes d'accès aux bâtiments
- Faire plusieurs montées-descentes pour chaque ascenseur
- Faire plusieurs tours de chaque étage du bâtiment pour enregistrer un total de 20 coins de bâtiments. Varier la vitesse de marche au long de l'acquisition.

²⁰ Cette condition peut être relâchée grâce à des méthodes de reconnaissance du mode de portage [18].



Figure 58 : Site géographique où la collecte de signal a eu lieu

IV.4.4 Indexation du signal

IV.4.4.1 Analyse de signal

Le comportement du signal est analysé durant les régimes permanents des classes de mouvement. Nous nous intéressons dans cette section au choix des signaux qui sont matière au calcul des entrées de l'algorithme de classification, à savoir les descripteurs. Cette phase vise à chercher d'éventuelles signatures propres à chaque classe. Nous définissons une signature comme la forme particulière et systématique que prend le signal au moment de la réalisation d'une classe. Cette forme est contenue dans le segment (ou série temporelle) défini(e) par la suite des valeurs prises par le signal sur une fenêtre correspondant à $N \in \mathbb{N}^*$ points :

$$S = \{s_1 \quad \dots \quad s_N\} \quad \text{E. 74}$$

Cette étape peut passer par une transformation du signal [102] dans des domaines où les classes présenteraient potentiellement des signatures plus significatives.

- Gyromètre

Pour illustrer la notion de signature, prenons l'exemple d'un piéton qui tient l'IMMU dans sa main et pousse une porte battante pour accéder à un bâtiment. Au moment de l'ouverture de la porte, le corps du piéton accompagne le mouvement de cette dernière en effectuant une rotation qui est retrouvée dans le signal du gyromètre (Figure 59). La forme du signal délivré par le gyromètre et correspondant à l'événement « Ouverture de porte battante » est une signature. Cette signature disparaît dès lors que les portes glissantes sont prises en compte car le mouvement de rotation n'est plus distinctif de la classe en question.

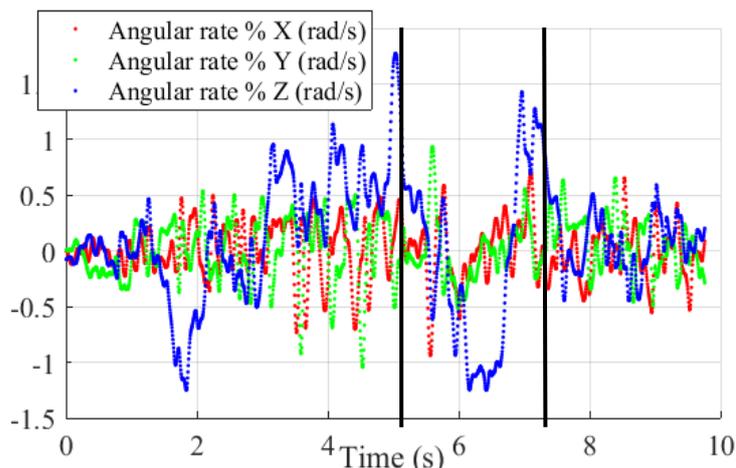


Figure 59 : Signature du gyromètre au moment d'un franchissement de porte battante. (4.9s-7s).

La figure précédente présente la vitesse angulaire dans le repère body du gyromètre selon les trois composantes x,y et z. Cette décomposition devrait être transposée au repère de navigation pour interpréter le signal de manière adaptée à la carte (ex. ici la variance maximale se fait selon l'axe z car le capteur est tenu en main en mode Texting, de manière parallèle au sol. La variation traduit alors principalement l'angle de lacet qui est la rotation par rapport à la composante verticale du repère de navigation), ce qui présuppose de connaître l'attitude du capteur. L'estimation de cette dernière étant de plus en plus imprécise au cours du temps, le choix est finalement porté sur la norme du signal exprimé dans le repère body. De cette façon la connaissance de l'attitude du capteur n'est pas nécessaire. Le gyromètre permet également de distinguer les phases statiques et les ascenseurs car ce sont des régimes pendant lesquels le piéton ne réalise pas de rotation. Notons que dans cet exemple, le motif correspondant à l'ouverture de porte dure environ 2s.

- Accéléromètre

La norme du signal est considérée pour les mêmes raisons que pour le signal du gyromètre. Le signal d'accélération est particulièrement intéressant pour la discrimination des phases statiques ou pour les montées/descentes d'ascenseurs (Figure 60). Il présente également un motif systématique durant les ouvertures de portes car le piéton décélère pour ouvrir la porte, puis accélère une fois que cette dernière est franchie pour accéder au bâtiment (Figure 61). Cette signature est plus visible sur l'enveloppe supérieure du signal plutôt que sur le signal lui-même à cause des bruits et de la fréquence d'échantillonnage assez élevée du signal brut (200 Hz). La distinction au niveau de l'enveloppe supérieure entre les ouvertures de portes et la marche normale peut être visualisée par comparaison avec la Figure 62. L'amplitude des variations au niveau de l'enveloppe d'accélération est en effet beaucoup plus importante pour les ouvertures de portes. Le motif correspondant forme une parabole convexe plus ou moins symétrique selon l'axe vertical. Le motif d'ouverture de porte a ici une longueur temporelle d'environ 3s.

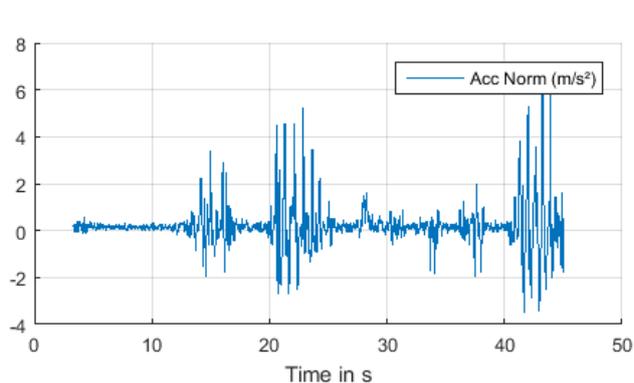


Figure 60 : Signal d'accélération en mode statique (entre 3 et 12s) puis dans un ascenseur (régime permanent entre 25 et 40 s).

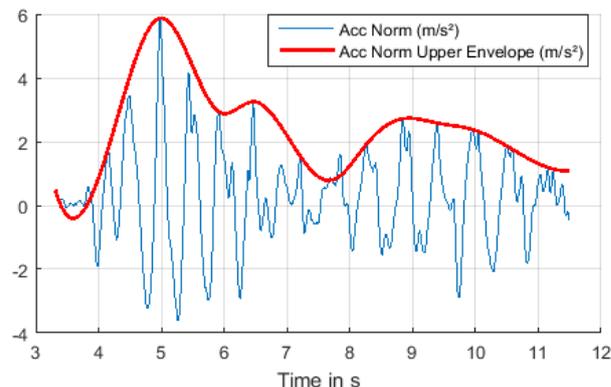


Figure 61 : Motif d'accélération lors d'une ouverture manuelle de porte battante (entre 6 et 9 s)

Le calcul d'enveloppe est réalisé directement sur la norme d'accélération. Il utilise la fonction « envelope » de Matlab [103] qui est définie comme suit:

$$envelope(t) = \sqrt{x(t)^2 + \hat{x}(t)^2} \quad E. 75$$

où $\hat{x}(t)$ est la forme analytique du signal correspondant à un complexe dont la partie réelle est $x(t)$ et la partie imaginaire est la transformée de Hilbert de $x(t)$ [104].

Même si l'enveloppe supérieure de la norme d'accélération montre des avantages pour la détection des ouvertures de portes, la norme du signal brut est également retenue car elle reflète plus finement des aspects de la marche tels que la fréquence, l'énergie, etc. Elle permet par exemple de discriminer les régimes à faible énergie comme les phases statiques ou dans les ascenseurs. Le gradient de l'enveloppe supérieure d'accélération est aussi pris en compte pour une meilleure description de la forme du signal.

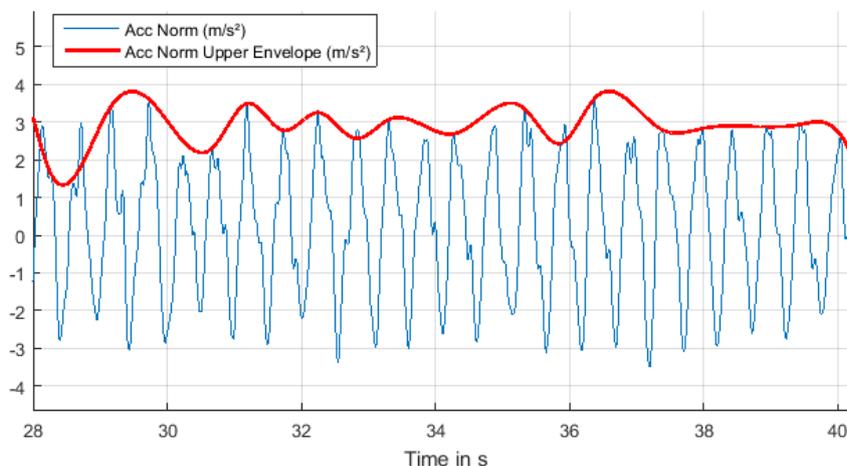


Figure 62 : Signal d'accélération pendant la marche

- Pression

La pression est d'abord filtrée car le signal présente beaucoup de bruits sous sa forme brute (Figure 63).

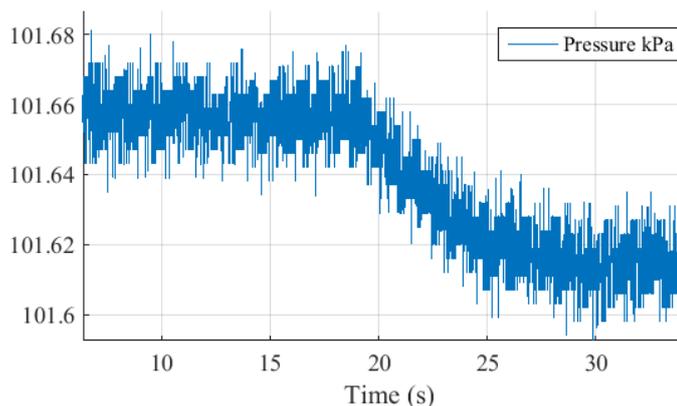


Figure 63 : Signal brut de la pression pour une montée d'ascenseur

Les filtres utilisés pour lisser le signal de pression, et ultérieurement le champ magnétique, sont de type forward-backward. Nous avons utilisé une fonction implémentée dans Matlab sous le nom « filtfilt ». Le filtre passe-bas utilisé est un Butterworth d'ordre 2 et de fréquence de coupure 5Hz. Les figures suivantes montrent à la fois le signal filtré en bleu, mais aussi la moyenne de ses deux enveloppes supérieure et inférieure après filtrage. En effet, il n'est pas intéressant d'étudier les variations du signal à hautes/moyennes fréquences qui subsistent malgré le filtrage. Sur une fenêtre temporelle supérieure ou égale à 1s, l'enveloppe moyenne permet de rendre compte de la variation globale du signal : sa pente, sa monotonie et son sens de variation.

La Figure 64 et la Figure 65 montrent respectivement la variation de pression lors d'une montée d'ascenseur puis d'escaliers. On peut noter que le sens de variation est le même, reflétant le lien direct entre la variation de hauteur et la variation de pression. Par ailleurs, la pente du signal est plus importante pour l'ascenseur, ce qui reflète ce même lien de pression avec la hauteur qui varie plus rapidement dans les ascenseurs.

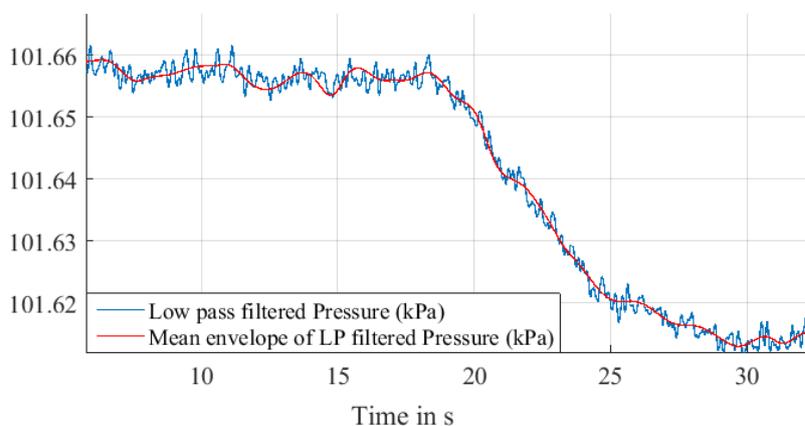


Figure 64 : Montée d'ascenseur (19s-24s)

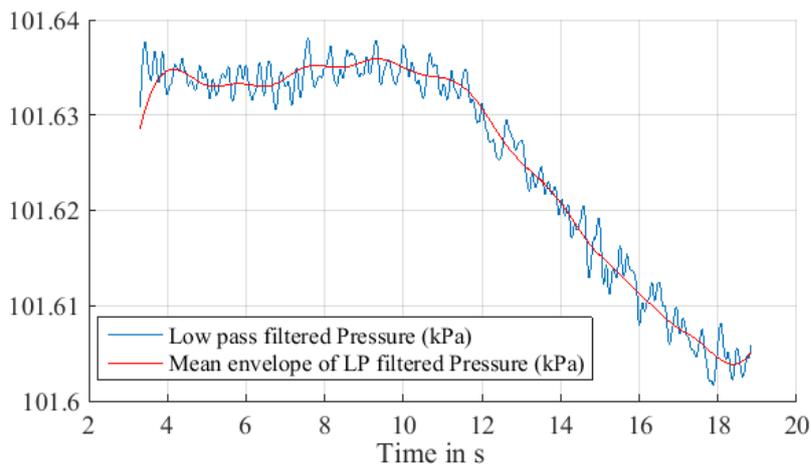


Figure 65 : Montée d'escaliers (11s-18s)

La Figure 67 et la Figure 68 montrent respectivement l'enveloppe moyenne de la pression filtrée et la norme d'accélération ainsi que son enveloppe supérieure pour une ouverture de porte automatique glissante. Dans le premier cas, il n'y a pas de signature. Dans le cas de l'accélération, la forme parabolique est retrouvée (10s-12s). Ce motif est dupliqué (deux paraboles au lieu d'une seule) dans l'enveloppe supérieure principalement à cause d'une imprécision de calcul, ce qui ne peut être évité à 100%. La duplication du motif est prise en compte dans la sélection des descripteurs et donc dans l'apprentissage. En effet, puisque les motifs d'une même classe sont de longueurs temporelles diverses, cette dernière est intégrée comme variable descriptive en entrée des méthodes de sélection. Les résultats de la section VI.1.1 montreront que la longueur temporelle n'est pas une variable importante dans la différenciation des classes.

La Figure 66 montre le motif de pression présenté dans l'étude [80] qui s'est intéressée à la détection des ouvertures de portes grâce à la mesure de pression. Ce motif est en effet noyé dans le signal de la Figure 67 car dans le cas de [80] le smartphone était en mode statique, posé au sol, tandis que dans cette étude le capteur est en mouvement, c'est-à-dire sujet à plusieurs perturbations qui empêchent l'existence d'une signature identifiable lors des ouvertures de portes.

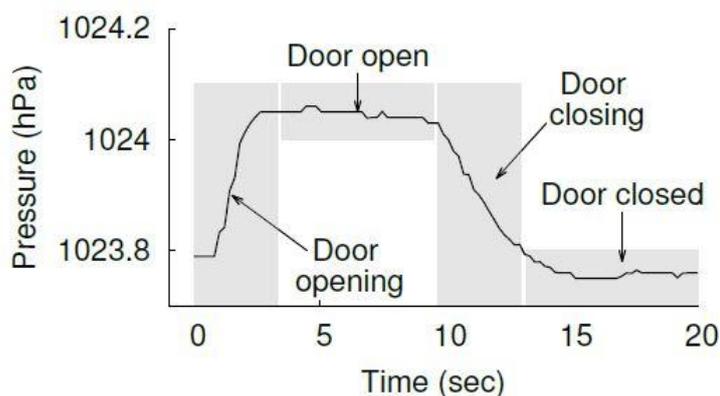


Figure 66 : Signature de pression présentée dans [80] par un smartphone posé au sol

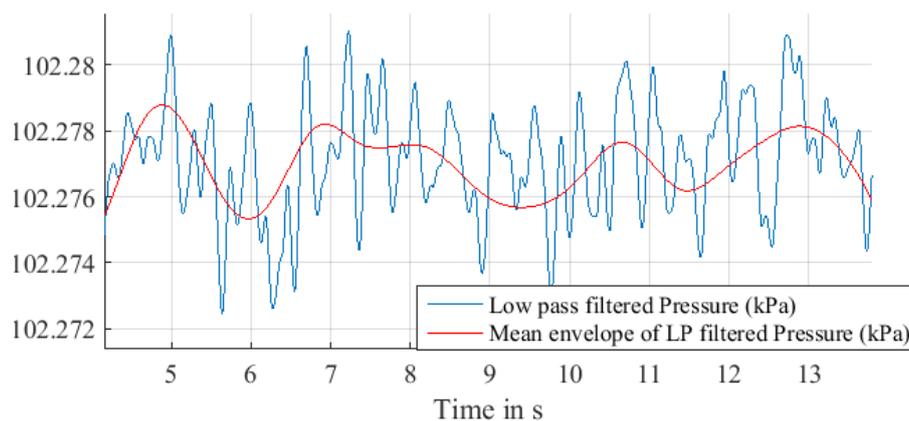


Figure 67 : Absence de signature de pression pour l'accès au bâtiment par une porte automatique glissante (10s-12s)

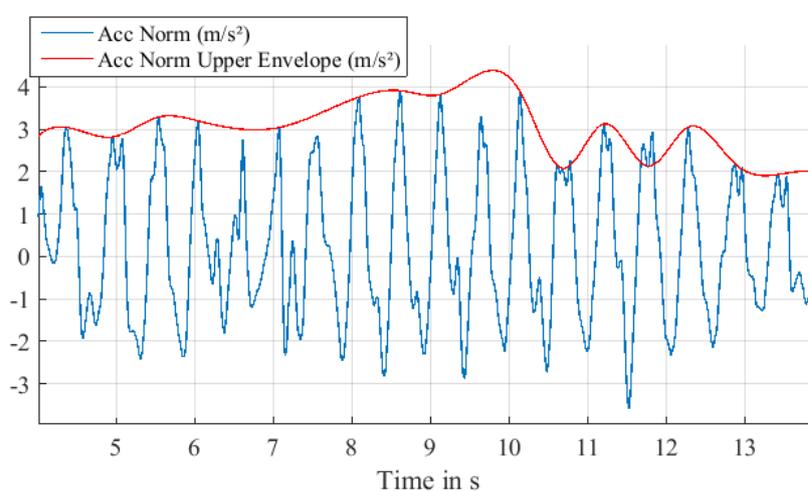


Figure 68 : Motif d'accélération associé à l'accès au bâtiment par une porte automatique glissante (10s-12s)

- Champ magnétique

Le champ magnétique est plus variable dans les espaces indoor et peut être exploité pour la détection IO (Sections IV.1 et IV.2). Ici, il est filtré comme précisé au paragraphe précédent avec la fonction *filtfilt* de Matlab. En général la norme du champ magnétique est considérée dans la reconnaissance de l'indoor et des ascenseurs. Il n'y a pas de signature spécifique à une classe au niveau du champ magnétique. Néanmoins, nous garderons la norme du signal filtré ainsi que son gradient pour le calcul des descripteurs. L'hypothèse sous-jacente est qu'il existerait des tendances de variation du champ magnétique entre l'indoor et l'outdoor (comme il en existe une pour la pression qui augmente en indoor d'après [80]).

Au terme de cette analyse du signal, 8 chaînes de signal listées dans la Table 6 ont été retenues.

N°	Chaîne de signal	Notation / Préfixe
1	Norme de l'accélération	Acc_
2	Norme du champ magnétique filtré	Mag_
3	Gradient de la norme du champ magnétique filtré	Grad_Mag_
4	Norme de la vitesse angulaire	Gyro_
5	Enveloppe moyenne de la pression filtrée	Pres_
6	Gradient de l'enveloppe moyenne de la pression filtrée	Grad_Pres_
7	Enveloppe supérieure de la norme d'accélération	AccUpEnv_
8	Gradient de l'enveloppe supérieure de la norme d'accélération	Grad_AccUpEnv_

Table 6 : Chaînes de signal considérées et leurs préfixes correspondants

IV.4.4.2 Indexation du signal

L'isolation des phases du signal correspondant à la réalisation des classes de mouvement passe par l'extraction et l'étiquetage de ce dernier. La procédure de segmentation et d'étiquetage du signal est appelée indexation de série temporelle et est naturellement réalisée de manière manuelle. C'est une étape décisive car une mauvaise indexation du signal introduirait des erreurs d'apprentissage. Comme on dispose de plusieurs signaux pour chaque motif, un segment est une série temporelle à plusieurs chaînes ou canaux. Les chaînes de signal de chaque segment sont temporellement synchrones et ont la même fréquence d'échantillonnage (200 Hz). Aussi, l'indexation d'une seule chaîne équivaut à l'indexation de toutes les autres. La transformation des segments d'apprentissage dans des domaines autres que temporels est faite ultérieurement au moment du calcul des descripteurs. Afin d'éviter les erreurs d'indexation, un marquage temporel des instants de début et de fin de chaque réalisation est appliqué sur des signaux de démonstration. Ceci est réalisé en provoquant manuellement un pic d'accélération au niveau du capteur (provocation d'une secousse par la main) en début et à la fin de la réalisation des classes de mouvement. L'indexation du signal est alors obtenue par comparaison visuelle des signaux collectés avec les signaux de démonstration. Ces derniers ne sont pas utilisés dans la constitution des modèles de classification afin d'éviter l'introduction de bruits provenant du marquage temporel. L'indexation est ainsi proche de la réalité tant au niveau de la ressemblance avec les données de démonstration qu'au niveau des inexactitudes liées à la manière dont le marquage est réalisé (par un individu).

En appliquant cette procédure, des segments de longueurs temporelles différentes ont été extraits. En effet, il y a des classes pour lesquelles la longueur temporelle est fixe. Il s'agit de la marche normale, des escaliers et des ascenseurs. Pour les changements de direction et les franchissements de portes, l'étude de signal a montré que les motifs avaient des longueurs variables. L'indexation de ces segments a été réalisée grâce au mode d'emploi décrit au paragraphe précédent. Les longueurs temporelles des fenêtres sont récapitulées à la Table 7. Les longueurs variables sont notées « X ».

Classe	Co	US	DS	NW	EU	ED	Do_Exit	Do_Entry
Longueur de fenêtre	Xs	1.5s	1.5s	1.5s	1s	1s	Xs	Xs

Table 7 : Longueur de fenêtre pour chaque classe de mouvement

IV.4.5 Calcul des descripteurs

IV.4.5.1 Intérêt des descripteurs pour la reconnaissance de mouvements piétons

La reconnaissance du signal peut parfois se faire sans calcul de descripteurs. C'est le cas pour la DTW²¹ [105] qui réalise des mesures de similitude entre séries temporelles. Cependant, ces méthodes sont plutôt adaptées pour la reconnaissance de motifs systématiques comme les lettres de l'alphabet, les formes naturelles, les séquences d'ADN [106], etc. Elles ont l'inconvénient de présenter un temps de traitement considérable car l'appariement est fait pour chaque échantillon du signal, bien qu'il existe des méthodes de réduction du temps de traitement [107]. Par conséquent, plus la fréquence d'échantillonnage du signal est haute, plus le temps de calcul est important. Tout cela rend une telle approche peu appropriée notamment pour une navigation en temps réel. En effet, la fréquence d'échantillonnage doit être élevée afin de capturer le mouvement à la fois dans ses détails et sa globalité. Cela sert à étudier la vitesse de déplacement par une analyse de fréquence, de réaliser une classification pour reconnaître le mode de portage, les phases statiques, etc. Par ailleurs, les signaux inertiels et magnétiques induits par les mouvements piétons ne présentent pas réellement de motif systématique du fait d'une grande variabilité inter-environnementale et interindividuelle. Aussi, une approche statistique s'avère plus convenable. Elle consiste à représenter chaque série (ou segment) temporelle par un ensemble de variables descriptives. Chaque variable correspond à un descripteur ou attribut²².

IV.4.5.2 Descripteurs calculés

Etant donné que l'état de l'art en matière de capteurs de navigation n'a pas montré de résultats concluants quant aux descripteurs pertinents pour reconnaître les classes, notamment les franchissements de portes, nous nous proposons de calculer un ensemble de descripteurs dans les domaines temporel et fréquentiel (Table 8), et ce pour chacune des chaînes de signal retenues en IV.4.4.1 (Table 6). Ensuite, ces descripteurs sont introduits en entrée des trois algorithmes de sélection présentés en IV.3.3. L'apprentissage avec des algorithmes de classification sera ensuite réalisé pour chacun des résultats de la sélection.

N°	Nom du descripteur	Notation / Suffixe
1	Root Mean Square	_RMS
2	Variance	_Var
3	Maximum	_Max
4	Maximum de la valeur absolue	_MaxABS
5	Valeur moyenne	_Moy
6	Energie	_NRJ
7	Hauteur (= Max-Min)	_Height
8	Fréquence fondamentale (Analyse de Fourier)	_Fr
9	Amplitude associée à la fréquence fondamentale	_A
10	Durée temporelle	_Time

Table 8 : Descripteurs calculés sur la base de chaque chaîne de signal

Chaque individu d'apprentissage, dit aussi échantillon, est composé de 8 chaînes de signal. L'ensemble des descripteurs de la Table 8 est calculé pour chaque chaîne. Un individu d'apprentissage est donc décrit par un nombre de 8x10 variables descriptives avant le processus de sélection des descripteurs pertinents.

IV.4.5.3 Bilan sur la base de données d'apprentissage

La base de données d'apprentissage a une taille de 2266 échantillons utilisés dans une approche de

²¹ Dynamic Time Warping [105]

²² Les deux termes sont utilisés de manière équivalente

validation croisée. La base de données de validation a, quant à elle, une taille de 800 échantillons. 4 personnes ont contribué à l'apprentissage contre 4 pour la validation. En moyenne, pour la base de données d'apprentissage, nous avons pu extraire 566 échantillons toutes classes confondues par personne. Pour les données servant uniquement pour la validation, collectées par de nouveaux utilisateurs dans de nouveaux environnements, nous avons en moyenne 200 échantillons par personne. 3 bâtiments ont servi pour l'apprentissage et 3 pour la validation.

Chaque échantillon correspond à un segment à 8 chaînes de signal. Pour chacune de ces chaînes 10 descripteurs sont calculés, ce qui fait un tableau de 2266 lignes et de 81 colonnes dont la dernière correspond à la classe des échantillons. Une matrice de taille $\left(2266 \times \frac{2}{3}\right) \times N_p$ devrait donc être utilisée pour l'apprentissage avec N_p le nombre de descripteurs retenus après la sélection. Le nombre de lignes est multiplié par $\frac{2}{3}$ car le tiers restant sert comme données test pour une validation croisée. A l'issue de cette dernière, un classifieur global est calculé avec l'ensemble des données d'apprentissage. Il est ensuite utilisé pour prédire les classes des échantillons de validation afin d'évaluer sa capacité de généralisation.

Le processus de détection des POIs est décrit dans la section 0. Les résultats de la reconnaissance sont donnés à la section V.3.5.

IV.4.6 Variabilité des longueurs de fenêtres dans le processus de détection

La manière dont la détection des POI intervient dans le filtre est présentée à la section V.3.5. Néanmoins, le pseudo-algorithme fourni ne traite pas des longueurs temporelles variables d'une classe à l'autre. L'implémentation du filtre avec détection des POIs a en effet été réalisée avec le modèle simplifié où toutes les classes ont la même longueur temporelle. Nous proposons dans cette section une manière de tenir compte de cette variabilité pour le modèle évolué :

- Fixer trois longueurs temporelles :
 - 1.5s (Marche normale, escaliers, ascenseurs)
 - Durée moyenne des fenêtres correspondant à un changement de direction (entre 1.5 et 2s)
 - Durée moyenne correspondant aux franchissements de portes (en moyenne environ 3.5s)
- Segmenter le signal en ligne selon les trois fenêtres temporelles et réaliser une classification pour chacune des fenêtres
- Introduire un coefficient de confiance ρ sur la sortie de la classification :

$$\rho = \frac{t_{\text{segmentation}}}{t_{\text{moy}}(\text{classe})} \quad \text{E. 76}$$

Où $t_{\text{segmentation}}$ est la longueur de fenêtre de la segmentation et $t_{\text{moy}}(\text{classe})$ est la longueur temporelle moyenne de la sortie de la classification.

- si $\rho \gg Th$ ou $\rho \ll Th$, rejeter la classe.
- Sinon, la classe peut être prise en compte
- Dans le cas où la classe est prise en compte, continuer vers la recherche de POI au voisinage de la position propagée dans le filtre.
 - Si la recherche est positive, confirmer la détection d'un POI
 - Sinon abandonner le processus de classification et continuer le filtrage sans POI.

Chapitre V

V. HYBRIDATION CARTE-IMMU-MAGNETOMETRE-BAROMETRE	84
V.1 Théorie du filtrage Bayésien	84
V.1.2 Filtrage Bayésien	85
V.1.3 Résolution des équations du filtrage Bayésien	86
V.2 Etat de l'art : Méthodes de fusion des données de la carte avec les signaux	89
V.2.1 Utilisation d'un graphe avec un filtre de Kalman	89
V.2.2 Utilisation d'un graphe avec un filtre particulaire	92
V.2.3 Utilisation d'un espace borné avec un filtre de Kalman	93
V.2.4 Utilisation d'un espace borné avec un filtre particulaire	93
V.3 Conception du filtre particulaire réalisant le calcul de position	95
V.3.1 Initialisation	95
V.3.2 Modèle de propagation	96
V.3.3 Mise à jour	98
V.3.4 Ré-échantillonnage	99
V.3.5 Intégration des POIs	100

V. Hybridation Carte-IMMU-Magnétomètre-Baromètre

Ce chapitre vise à présenter le filtre particulière adopté pour le calcul de position. La partie V.1 établit les bases théoriques du filtrage Bayésien. La partie V.2 fait un état de l'art sur l'emploi de ces filtres pour la fusion des données inertielles et magnétiques avec la carte, enfin, la partie V.3 présente le détail du filtre particulière conçu pour pallier les différentes difficultés laissées en suspens dans l'état de l'art, notamment l'estimation du biais angulaire entre le cap de marche et l'orientation du capteur, la calibration du modèle de longueur de pas ou encore les erreurs de détection de pas.

V.1 Théorie du filtrage Bayésien

Cette section expose la théorie du filtrage Bayésien dans le cadre des modèles de Markov cachés. Les notions probabilistes utilisées ainsi que le détail des notations se trouvent en Modèles de Markov cachés

V.1.1.1 Chaîne de Markov (cas discret)

Un processus stochastique formant la suite $\{U_k\}_{k \in [0, n]}$ où $U \in \mathbf{U} \subset \mathbb{R}^d$ est une chaîne de Markov s'il vérifie :

$$\forall (k, l) \in \mathbb{N} \times \mathbb{N}^* : \{U\}_{l > k} \perp \{U\}_{l < k} \mid U_k \quad \text{E. 77}$$

Le symbole \perp signifie « indépendant de », et le symbole \mid désigne « conditionnellement à ».

Autrement dit, la suite des réalisations futures ($l > k$) est indépendante des réalisations passées ($l < k$) conditionnellement à la réalisation courante (k).

De ce fait, un processus de Markov est entièrement déterminé par la loi marginale de U à l'instant initial, notée p_{U_0} , ainsi que par une densité de probabilité conditionnelle $p_{U_{k+1} \mid U_k}$.

V.1.1.2 Modèles de Markov cachés

Considérons deux processus stochastiques $\{X_k\}_{k \in [0, n]}$ et $\{Y_k\}_{k \in [0, n]}$ où $n \in \mathbb{N}^*$ tels que :

- $\{X_k\}_{k \in [0, n]}$ est une suite de variables d'états cachés, *càd.* que la variable X n'est pas observable.
- $\{Y_k\}_{k \in [0, n]}$ est une suite de variables issues de mesures, naturellement observables.

Ces deux processus constituent un modèle de Markov caché si :

$$(X_{k+1}, Y_k) \perp (X_{1:k-1}, Y_{1:k-1}) \mid X_k \quad \text{E. 78}$$

Ce qui est équivalent aux trois postulats suivants :

- $\{X_k\}_{k \in [0, n]}$ constitue une chaîne de Markov, i.e. : $p_{X_{k+1} \mid X_{1:k}} = p_{X_{k+1} \mid X_k}$
- La suite des observations $\{Y_k\}_{k \in [0, n]}$ est indépendante conditionnellement à la suite des états:

$$p_{Y_{1:k} \mid X_{1:k}} = \prod_{k=1}^n p_{Y_k \mid X_{1:k}} \quad \text{E. 79}$$

- L'expression précédente peut être simplifiée sous la forme :

$$p_{Y_{1:k} \mid X_{1:k}} = \prod_{k=1}^n p_{Y_k \mid X_k} \quad \text{E. 80}$$

V.1.1.3 Loi d'observation et vraisemblance

A x fixé, la densité de la loi d'observation est donnée par la fonction $y \mapsto p_{Y|X}(y, x)$.

A y fixé, il s'agit d'une vraisemblance donnée par la fonction $x \mapsto p_{Y|X}(y, x)$.

V.1.1.4 Caractérisation d'un modèle de Markov caché

D'après les parties abordées précédemment, un modèle de Markov caché est entièrement caractérisé par :

- Une densité initiale p_{X_1} ,
- Une loi de transition $\forall k \geq 1 : p_{X_{k+1}|X_k}$. En pratique, on dispose d'une fonction dite de transition telle que :

$$\begin{aligned} f_k : \mathbf{X} &\rightarrow \mathbf{X} \\ x_{k-1} &\mapsto x_k = f_k(x_{k-1}, v_{k-1}) \end{aligned} \quad \text{E. 81}$$

où v_{k-1} est le bruit du modèle de transition.

- Une loi dite d'émission, correspondant à une loi de vraisemblance de densité $p_{Y_k|X_k}$. Elle est aussi induite par un modèle d'observation donné par :

$$\begin{aligned} h_k : \mathbf{X} &\rightarrow \mathbf{Y} \\ x_k &\mapsto y_k = h_k(x_k, n_k) \end{aligned} \quad \text{E. 82}$$

où n_k est le bruit du modèle d'observation.

V.1.2 **Filtrage Bayésien**

Dans le cadre des chaînes de Markov cachées, cette partie vise à expliquer la récurrence permettant, à partir d'une séquence d'observations $Y_{1:k}$, d'estimer l'état courant X_k et de prédire X_{k+1} ainsi que Y_{k+1} . A chaque instant k seront donc associés une observation Y_k ainsi qu'un état X_k dont les réalisations seront respectivement mesurée et estimée. Notons que $k \geq 1$ et que la première observation est valable pour $k = 1$. A l'instant (0) seul un état caché existe.

V.1.2.1 Initialisation

L'initialisation est donnée par la densité de probabilité a priori de l'état initial p_{X_1} qui est la même que $p_{X_1|Y_0}$ étant donné l'absence d'observation à l'instant(0).

V.1.2.2 Récurrence

Le filtrage Bayésien se déroule en trois étapes :

- Il s'agit d'abord de calculer la loi a priori sur l'état courant conditionnellement aux observations précédentes, de densité $p_{X_k|Y_{1:k-1}}$. Ceci est donné par l'équation de Chapman-Kolmogorov :

$$p_{X_k|Y_{1:k-1}}(x^+) = \int p_{X_k|X_{k-1}}(x^+, x) \cdot p_{X_{k-1}|Y_{1:k-1}}(x) dx \quad \text{E. 83}$$

où x^+ est la prédiction de l'état, $p_{X_k|X_{k-1}}$ est la loi de probabilité de transition et $p_{X_{k-1}|Y_{1:k-1}}$ est connue de par la récurrence.

- Ensuite, il s'agit de calculer la loi a priori sur l'observation courante conditionnellement aux

observations précédentes, de densité $p_{Y_k|Y_{1:k-1}}$. Cette dernière est donnée par l'équation :

$$p_{Y_k|Y_{1:k}}(y) = \int p_{Y_k|X_k}(y, x) p_{X_k|Y_{1:k-1}}(x) dx \quad \text{E. 84}$$

où $p_{Y_k|X_k}$ est la loi d'observation.

- Enfin, une fois qu'une observation y_k est disponible à l'instant courant, il devient possible de mettre à jour l'état courant en calculant la densité a posteriori de X_k via la vraisemblance de densité $p_{Y_k|X_k}$:

$$p_{X_k|Y_k}(x) = \frac{p_{Y_k|X_k}(y_k, x) p_{X_k|Y_{1:k-1}}(x)}{p_{Y_k|Y_{1:k-1}}(y_k)} \quad \text{E. 85}$$

Le principe du filtrage Bayésien consiste à résoudre de manière récursive la densité a posteriori de l'état. Le but est bien évidemment d'avoir une meilleure estimation de l'état a posteriori (càd. après mesure). Il s'agit d'un problème d'optimisation où l'erreur considérée est l'erreur d'estimation de l'état X_k . Une façon de caractériser un estimateur consiste à déterminer son biais et sa variance. Une manière plus simple est de considérer son erreur moyenne quadratique (RMSE pour *Root Mean Square Error*). Pour réduire cette dernière, la solution optimale est l'espérance conditionnelle $\hat{x}_k = E[X_k | Y_{1:k} = y_{1:k}]$ et c'est ce que les méthodes ci-dessous permettent d'estimer.

V.1.3 Résolution des équations du filtrage Bayésien

Les équations du filtrage Bayésien n'admettent une solution analytique que pour un nombre de cas limité. Il s'agit des cas linéaires à bruits Gaussiens, c'est-à-dire lorsque les modèles de transition et d'observation sont linéaires et que les bruits des modèles sont Gaussiens. Dans ce cas, la résolution se fait par application d'un filtre de Kalman optimal [108]. Sinon, dans les cas non linéaires à bruits Gaussiens, il est possible de calculer une solution sub-optimale en appliquant un filtre de Kalman étendu [108]. Enfin, dans les cas où les modèles sont fortement non linéaires ou que les bruits ne sont pas Gaussiens, il est préférable d'adopter un filtre particulière [109].

V.1.3.1 Filtres de Kalman

V.1.3.1.1 Filtre de Kalman (optimal)

Un filtre de Kalman considère qu'à chaque instant de la récursion les erreurs a posteriori sont Gaussiennes et que les modèles de prédiction et d'observation sont linéaires. Les erreurs sont alors modélisées par une moyenne et une variance conformément à la loi Normale. Dans ce cas, il s'agit d'un filtre optimal qui calcule exactement la densité a posteriori de l'état. Considérons le modèle de Markov caché suivant :

$$X_k = F_k \cdot X_{k-1} + n_{k-1} \quad \text{E. 86}$$

$$Y_k = H_k \cdot X_k + v_k \quad \text{E. 87}$$

où F_k est la matrice de transition et H_k la matrice d'observation. Q_{k-1} et R_k sont les matrices de variance/covariance respectivement associées à n_{k-1} et v_k . Enfin, la densité a posteriori $p_{X_k|Y_k}$ (à ne pas confondre avec la matrice de variance en majuscule) est aussi modélisée par une moyenne et une matrice de variance/covariance $P_{X_k|Y_k}$.

Prédiction de l'état

La matrice de (co)variance de la prédiction de l'état est donnée par (cf. Récurrence E. 83):

$$P_{X_k|Y_{k-1}} = F_k \cdot P_{X_{k-1}|Y_{k-1}} \cdot F_k^T + Q_{k-1} \quad \text{E. 88}$$

Prédiction de l'observation et calcul du gain de Kalman

La matrice de (co)variance de l'innovation est calculée par (cf. Récurrence E. 84):

$$P_{Y_k|Y_{k-1}} = H_k \cdot P_{X_k|Y_{k-1}} \cdot H_k^T + R_k \quad \text{E. 89}$$

et le gain de Kalman par :

$$K_k = P_{X_k|Y_{k-1}} \cdot H_k^T \cdot P_{Y_k|Y_{k-1}}^{-1} \quad \text{E. 90}$$

Mise à jour de l'état

Enfin, la variance de la densité a posteriori de l'état (cf. Récurrence équation E. 85) est calculée selon :

$$P_{X_k|Y_k} = P_{X_k|Y_{k-1}} - K_k \cdot H_k \cdot P_{X_k|Y_{k-1}} \quad \text{E. 91}$$

L'état est finalement estimé selon l'équation suivante:

$$\hat{X}_k = X_k^+ + K_k \cdot (Y_k - Y_k^+) \quad \text{E. 92}$$

où X_k^+ et Y_k^+ sont respectivement l'état et l'observation prédits, Y_k est l'observation et \hat{X}_k est l'estimée de l'état après mise à jour.

Lorsque les hypothèses de linéarité et/ou de normalité des distributions ne sont pas vérifiées, on parle de filtres sub-optimaux car la solution est seulement une approximation. C'est le cas des variantes de filtres de Kalman : étendu (extended), sans parfum (unscented), ou des approximations de Monte Carlo (filtres particulaires).

V.1.3.1.2 Filtre de Kalman étendu (EKF)

Ce filtre permet de gérer les modèles non linéaires à distributions Gaussiennes. Les modèles de prédiction et d'observation s'écrivent dans ce cas :

$$X_k = f_k(X_{k-1}, n_{k-1}) \quad \text{E. 93}$$

$$Y_k = h_k(X_k, v_k) \quad \text{E. 94}$$

Un étape préalable consiste à calculer le développement de Taylor des fonctions f et h à l'ordre 1, ce qui revient à les linéariser :

$$\tilde{F}_k = \left. \frac{df_k(x)}{dx} \right|_{x=X_{k-1}} \quad \tilde{H}_k = \left. \frac{dh_k(x)}{dx} \right|_{x=X_k^+}$$

Ensuite, les matrices de variances/covariances sont calculées de la même manière que pour un filtre de Kalman, avec les matrices de transition et d'observation calculée ci-dessus.

Prédiction de l'état

$$P_{X_k|Y_{k-1}} = \tilde{F}_k \cdot P_{X_{k-1}|Y_{k-1}} \cdot \tilde{F}_k^T + Q_{k-1} \quad \text{E. 95}$$

Prédiction de l'observation et calcul du gain de Kalman

$$P_{Y_k|Y_{k-1}} = \tilde{H}_k \cdot P_{X_k|Y_{k-1}} \cdot \tilde{H}_k^T + R_k \quad \text{E. 96}$$

Le gain de Kalman est alors donné par :

$$K_k = P_{X_k|Y_{k-1}} \cdot \tilde{H}_k^T \cdot P_{Y_k|Y_{k-1}}^{-1} \quad \text{E. 97}$$

Mise à jour de l'état

L'état et sa densité sont estimés grâce aux équations 98 et 99 :

$$P_{X_k|Y_k} = P_{X_k|Y_{k-1}} - K_k \cdot \tilde{H}_k \cdot P_{X_k|Y_{k-1}} \quad \text{E. 98}$$

$$\hat{X}_k = X_k^+ + K_k \cdot (Y_k - Y_k^+) \quad \text{E. 99}$$

V.1.3.1.3 Unscented Kalman filter (Filtre de Kalman sans parfum)

Les filtres de Kalman sans parfum (UKF) traitent les problèmes (fortement) non linéaires à distributions Gaussiennes en modélisant l'état par une population de particules. Les UKFs ne nécessitent donc pas de linéarisation des modèles. L'état est caractérisé à partir de la distribution des particules par une variance et une moyenne. Le nombre de particules sIMMULées est de $2n + 1$ où n est la taille du vecteur d'état. Elles sont tirées de manière déterministe à partir d'une première valeur de l'état accompagnée d'une variance (contrairement au tirage aléatoire des particules dans un filtre particulière). Bien qu'il existe plusieurs variantes d'UKFs, il est admis qu'ils sont tous plus performants que les EKF étant donné l'importante approximation que font ces derniers en linéarisant les modèles par développement de Taylor à l'ordre 1. Une fois que les particules ont été tirées, il convient alors de les propager par un modèle d'évolution puis de prédire autant d'observations qui seront comparées avec la mesure. Les matrices de covariances sont alors estimées de manière statistique, permettant d'appliquer les équations du filtrage de Kalman classiques et de mettre à jour l'état.

V.1.3.1.4 Filtre de Kalman multi-hypothèses

Dans les approches multi-hypothèses, il convient de déployer plusieurs filtres de Kalman. Les hypothèses sont créées ou détruites en fonction de la corrélation entre les prédictions et les observations. Une mesure de corrélation usuelle entre deux variables aléatoires Gaussiennes de moyennes et variances respectives (x_1, x_2) et (Σ_1, Σ_2) est donnée par :

$$D(x_1, x_2) = \frac{\exp\left(-\frac{1}{2}(x_1 - x_2)(\Sigma_1 + \Sigma_2)^{-1}(x_1 - x_2)^T\right)}{\sqrt{2\pi|\Sigma_1 + \Sigma_2|}} \quad \text{E. 100}$$

La modification du nombre d'hypothèses est gérée par seuillage [110]. Si la mesure de corrélation est en dessous d'un certain seuil pour toutes les hypothèses, cela signifie qu'il s'agit d'une nouvelle hypothèse à considérer. Au contraire, si la corrélation est importante pour plusieurs hypothèses, cela signifie qu'elles sont redondantes et qu'il ne faut en garder qu'une seule ou qu'il faut les fusionner. Le seuillage est généralement appliqué au gain de Kalman.

V.1.3.2 Filtre particulière

Les approches particulières se rapprochent des UKFs dans la mesure où elles modélisent l'état par une population de particules. Ces dernières sont en revanche simulées de manière aléatoire à partir d'une densité a priori, usuellement Gaussienne ou uniforme.

L'initialisation d'un filtre particulière consiste à tirer des particules à partir d'une première valeur de l'état \hat{X}_1 de densité de probabilité $p_{x_1|y_1}$. La récurrence se déroule ensuite en trois étapes :

Prédiction de l'état

Admettons qu'à l'instant $k - 1$ la distribution a posteriori de l'état est connue et qu'elle s'écrit :

$$p_{x_{k-1}|y_{k-1}}(x) = \sum_{i=1}^N \omega_{k-1}^i \cdot \delta(x - \xi_{k-1}^i) \quad \text{E. 101}$$

Cette équation traduit le fait que N particules ξ sont sIMMULées à l'instant $k - 1$ et qu'elles ont chacune un poids ω^i . δ est l'opérateur Dirac signifiant que :

$$\begin{cases} \delta(x - a) = 1 & \text{si } x=a \\ \delta(x - a) = 0 & \text{sinon} \end{cases} \quad \text{E. 102}$$

La distribution a posteriori est généralement uniforme, c'est-à-dire que toutes les particules sont équiprobables et qu'elles ont le même poids. Chaque particule sera propagée par le modèle de prédiction, ce qui ne change pas son poids. Notons l'ensemble des particules prédites $(\xi_k^i)_{i=1:N}^+$.

Prédiction de l'observation et calcul de vraisemblance

L'observation est aussi modélisée par un ensemble de particules $(\tilde{\xi}_k^i)_{i=1:N}$. Ces dernières résultent de la propagation des particules prédites $(\xi_k^i)_{i=1:N}$ par le modèle d'observation.

Lorsqu'une observation Y_k est disponible, la vraisemblance de chaque particule est calculée, permettant d'affecter un poids à chaque particule:

$$\omega_k^i = p_{Y_k|X_k}(Y_k, \tilde{\xi}_k^i) \quad \text{E. 103}$$

Ces poids sont normalisés afin d'être conformes avec l'expression d'une densité de probabilité :

$$\bar{\omega}_k^i = \frac{\omega_k^i}{\sum_{l=1}^N \omega_k^l} \quad \text{E. 104}$$

Mise à jour de l'état

Une fois que les poids ont été calculés, la densité a posteriori de l'état est approximée par :

$$p_{X_k|Y_k}(x) \approx \sum_{i=1}^N \bar{\omega}_k^i \cdot \delta(x - \xi_k^{i+}) \quad \text{E. 105}$$

Rééchantillonnage des particules (Resampling)

Parmi les problèmes inhérents aux filtres particulaires, une dégénérescence des particules peut être notée à cause du faible poids affecté à un grand nombre de particules. L'alternative consiste à réaliser un tirage aléatoire des particules conformément à la distribution a posteriori de l'état. En d'autres termes, il s'agit de favoriser les particules à fort poids en les dupliquant et de détruire celles qui ont un poids faible de manière à ce que leur nombre reste constant mais qu'elles participent toutes au processus de filtrage. Après ce rééchantillonnage, les particules sont propagées selon une loi uniforme ou Gaussienne et sont réintroduites dans la récurrence du filtrage Bayésien. Notons qu'à part cette dégénérescence, les filtres particulaires permettent de gérer les modèles non linéaires et des distributions quelconques. Ils sont d'autant plus pratiques qu'ils sont simples à implémenter et qu'un grand nombre important de particules peut être géré par des applications en temps réel grâce aux capacités de calcul aujourd'hui disponibles.

V.2 Etat de l'art : Méthodes de fusion des données de la carte avec les signaux

On parle de Map-aiding dans les approches où la carte intervient conjointement avec les capteurs dans un processus récursif permettant d'estimer la position du piéton. Dans ce cas, la carte est utilisée comme contrainte permettant de borner le support²³ de la variable d'état, la carte fournissant soit un graphe de navigation, soit un espace borné de navigation. Cette approche peut aussi couvrir des structures en volume en considérant les étages d'un bâtiment dans une représentation en 2.5D.

Les sections suivantes examinent la fusion des capteurs et carte dans deux types de filtres différents (Kalman et filtre particulaire). Ces filtres font récursivement l'évolution et la correction de l'état. La carte sert dans l'évolution, ou dans la correction, ou dans les deux (mais pas au même niveau : par exemple l'évolution est contrainte en position, tandis que la mesure du cap est tirée de la carte).

V.2.1 Utilisation d'un graphe avec un filtre de Kalman

Cette section présente deux exemples d'application d'un filtre de Kalman dans le cadre de l'utilisation d'un graphe. Le premier présente un filtre de Kalman étendu multi-hypothèses, réalisant à la fois la prédiction de l'état et sa correction. Le deuxième présente un filtre de Kalman sans parfum exploitant le graphe uniquement dans l'étape de correction.

²³ Le support d'une variable aléatoire étant l'ensemble des valeurs à probabilité non nulle qu'elle peut prendre.

V.2.1.1 EKF multi-hypothèses pour prédire et corriger l'état à l'aide d'un graphe [55]

Dans un graphe de navigation, l'exploration est limitée aux segments du graphe et les distributions sont naturellement multimodales. Une manière de traiter le problème de fusion d'un graphe avec les capteurs d'une IMU consiste à appliquer un filtre de Kalman multi-hypothèses, car un filtre de Kalman classique suppose une distribution Gaussienne monomodale. L'exploration du graphe se fait conformément au modèle de prédiction suivant :

$$X_{k+1} = X_k + \delta \cdot s_{k+1} + n_{k+1} \quad \text{E. 106}$$

où k est l'indice de temps, X est le vecteur d'état (abscisse curviligne sur un arc du graphe), s est la longueur de pas, δ une variable binaire déterminant le sens de parcours d'un segment et n un bruit Gaussien.

A chaque nœud rencontré plusieurs segments candidats sont explorés. Le nombre de segments considérés détermine le nombre de filtres de Kalman déployés, le tout conduisant à gérer un arbre (ensemble de filtres) dont la combinatoire peut être très grande.

Les mesures sont exploitées pour calculer un gain de Kalman pour chaque hypothèse (Figure 69), permettant de garder l'hypothèse qui présente le gain le plus important ou d'en garder plusieurs dans les approches multi-hypothèses. Les travaux de [55] sont un exemple d'application d'un EKF multi-hypothèses réalisant la fusion de capteurs inertiels, d'un baromètre, d'un graphe en 2.5D et d'émetteurs Bluetooth.

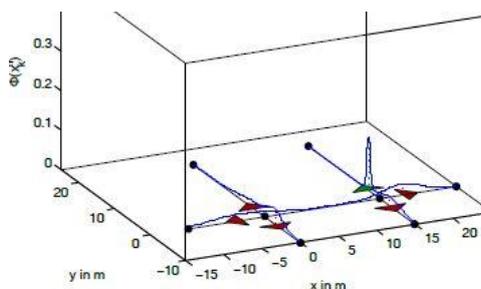


Figure 69: EKF multi-hypothèses pour explorer un graphe de navigation [55]

Cette méthode modélise les émetteurs Bluetooth par des nœuds qui sont intégrés au graphe, au même titre que les éléments caractéristiques du plan tels que les accès ou les intersections de couloirs. Un modèle dit 'log-distance path loss' permet de lier la puissance du signal mesurée à la distance à l'émetteur Bluetooth, lequel est déjà localisé dans la structure du graphe. De même, le capteur de pression est accompagné d'un modèle liant l'information de hauteur à la pression mesurée, ce qui permet d'appréhender les changements d'étages. Ces derniers sont modélisés par des segments verticaux. Enfin, la dernière mesure est donnée par les orientations des segments qui sont comparées aux caps PDR. On peut constater que la fusion ici exploite plusieurs sources d'informations. Cela est justifié par le fait que la modélisation par un graphe simplifié n'est adaptée que dans les structures marquées par la géométrie des couloirs, ce qui n'est pas le cas dans les zones ouvertes telles que les halls ou les places. A défaut de signal GNSS, les émetteurs Bluetooth apportent une mesure extéroceptive permettant de calibrer la position.

V.2.1.2 UKF pour corriger l'état à l'aide d'un graphe [68]

Dans d'autres travaux, l'aide d'un graphe de navigation vient en amont de l'application d'un filtre de Kalman (Figure 70). C'est le cas de [68] où la carte n'intervient pas dans la propagation de l'état. Le Map-matching n'est pas ici un objectif en soi, mais il permet d'apporter une mesure sur la variation de cap de marche qui servira au calcul de vraisemblance dans un UKF.

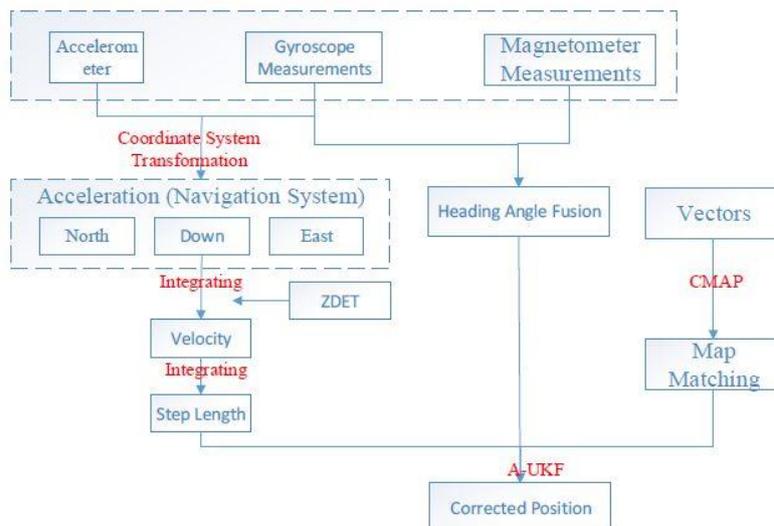


Figure 70: Map-matching en amont de l'application d'un UKF [68]

En effet, le cap de marche est ici intégré au vecteur d'état :

$$X_k = \begin{pmatrix} N_k \\ E_k \\ \theta_k \end{pmatrix} \quad \text{E. 107}$$

où

$$\theta_k = \theta_{k-1} + \tilde{\theta} \quad \text{E. 108}$$

$$N_k = N_{k-1} + \tilde{s} \cdot \cos(\theta_{k-1}) \quad \text{E. 109}$$

$$E_k = E_{k-1} + \tilde{s} \cdot \sin(\theta_{k-1}) \quad \text{E. 110}$$

avec \tilde{s} la longueur de pas et $\tilde{\theta}$ la variation angulaire délivrée par le gyromètre. N_k et E_k sont les positions Nord et Est du piéton.

L'aide du graphe consiste à apporter une mesure $\Delta\theta$ de la variation du cap de marche conformément au schéma de la Figure 71. En effet, si le piéton marche le long d'un couloir alors cette variation est négligeable, sinon on considère qu'il change de couloir, et la variation angulaire est d'environ 90° .

Le modèle d'observation associé s'écrit :

$$\Delta\theta_k = \theta_k - \theta_{k-1} \quad \text{E. 111}$$

Les caps de marche prédit et mesuré constituent les entrées d'un UKF réalisant la fusion.

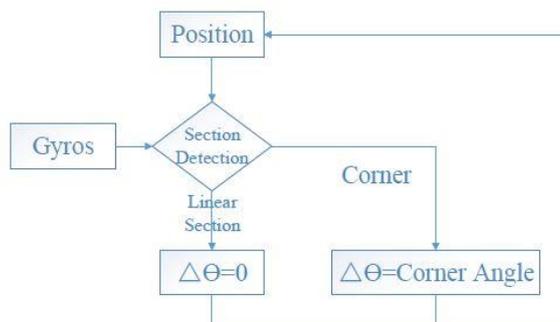


Figure 71: Calibration des caps de marche par map-matching [68]

Cette méthode s'apparente à l'exploration d'un graphe lorsque le piéton marche le long un couloir.

L'application de l'UKF reste limitée à ce cas de figure et ne traite pas l'exploration du graphe, ce qui d'ailleurs peut être relevé dans le modèle de transition qui n'est pas monodimensionnel.

V.2.1.3 Bilan sur l'utilisation des filtres de Kalman pour la fusion d'un graphe avec d'autres capteurs

Globalement, les travaux réalisant la fusion entre un graphe de navigation et des capteurs avec un filtre de Kalman restent assez rares. Cela est dû à plusieurs raisons. La première réside dans le besoin d'adapter le filtre en le linéarisant dans les EKF ou en modélisant l'état par une population de particules à distribution Gaussienne et de faible cardinal dans un UKF. La deuxième (et surtout celle-ci) est expliquée par le fait qu'il faut déployer un nombre de filtres variable en fonction des hypothèses, ce qui reste assez complexe en termes d'implémentation.

V.2.2 Utilisation d'un graphe avec un filtre particulaire

Dans les approches particulières, à chaque instant de pas, la position du piéton est modélisée par un ensemble de particules (qui sont elles-mêmes des positions géographiques distinctes les unes des autres). A chaque fois qu'une mesure est disponible, les particules propagées sont pondérées en fonction de leur adéquation (vraisemblance) avec la mesure. Enfin, le processus de rééchantillonnage permet de dupliquer les particules qui ont un poids fort et d'éliminer les autres. Cette dernière étape constitue la mise à jour de l'état qui permet d'estimer empiriquement la position du piéton.

Le modèle d'évolution pour un filtre particulaire est monodimensionnel et s'écrit de la même manière que précédemment :

$$X_{k+1} = X_k + \delta.s_{k+1} + n_{k+1} \quad \text{E. 112}$$

L'exploration est multimodale et elle est gérée par un seul filtre, contrairement aux filtres de Kalman multi-hypothèses. Ce système de propagation à l'aide d'un filtre particulaire a d'abord été introduit dans le cadre de la navigation automobile [111]. En effet, le graphe de navigation est directement donné par le réseau routier, contrairement au cas de la navigation piétonne où les hypothèses de déplacement sont beaucoup plus nombreuses.

Comme expliqué précédemment, les segments du graphe fournissent une mesure du cap de marche lorsque le mouvement est supposé rectiligne. Dans ce cadre, l'étude [112] réalise une fusion des capteurs d'une IMU avec un graphe grâce à un filtre particulaire. Cette approche est gérée par seuillage et permet à une particule d'évoluer uniquement sur les arcs ayant une orientation dont l'écart par rapport au cap de marche PDR est borné (Figure 72). Aussi, la trajectoire reconstruite par map-aiding prend les orientations du graphe et non les caps de marche PDR, corrigeant ainsi la dérive.

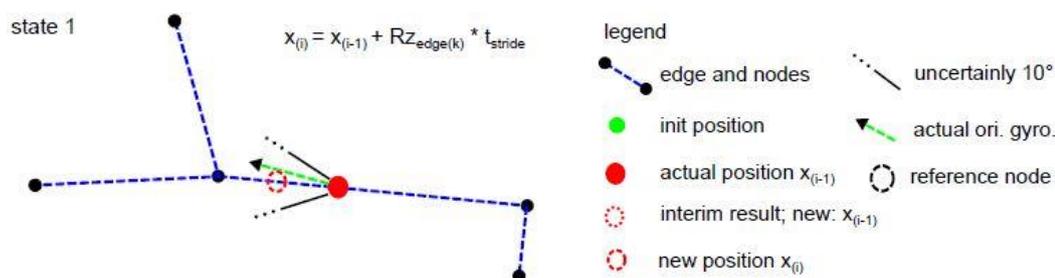


Figure 72: Evolution d'une particule sur un arc : la direction PDR et celle de l'arc présentent un écart inférieur à 10 [112]

Dans l'exemple précédent, la seule mesure considérée est celle des orientations des segments. Il est bien évidemment possible de combiner plusieurs mesures telles que la puissance du signal radio reçu ou la mesure de pression permettant de gérer la composante verticale. Néanmoins, la contribution de la carte revient souvent à mesurer le cap de marche. Les innovations sur les mesures permettent alors de pondérer les particules (Figure 73). A titre d'exemple, il convient de calculer la vraisemblance via un modèle conforme aux travaux de [111] développés dans le cadre de la navigation automobile. Ce modèle permet de combiner la position GNSS et la mesure du cap de marche et peut s'appliquer dans le cadre de la navigation piétonne :

$$\omega_{k+1}^i = \omega_k^i \cdot \exp\left(-\frac{1}{2} \cdot \frac{\theta_{PDR} - \theta_{k+1}^i}{\sigma_{\theta_{PDR}}^2 + \sigma_{\theta_{k+1}^i}^2}\right) \cdot \exp\left(-\frac{1}{2} \cdot \Delta_{GNSS}^{Tmap} \cdot \Sigma_{GNSS+map}^{-1} \cdot \Delta_{GNSS}^{map}\right) \quad E. 113$$

où ω est le poids de la particule, θ_{PDR} est le cap de marche PDR et $\sigma_{\theta_{PDR}}^2$ sa variance, θ_{k+1}^i est la direction de l'arc de la particule et $\sigma_{\theta_{k+1}^i}^2$ sa variance, Δ_{GNSS}^{map} est l'innovation entre la position GNSS et la particule, et $\Sigma_{GNSS+map}^{-1}$ la matrice inverse de la variance/covariance de la position GNSS et de la mesure de la carte (précision géométrique affectée à l'endroit où se trouve la particule).

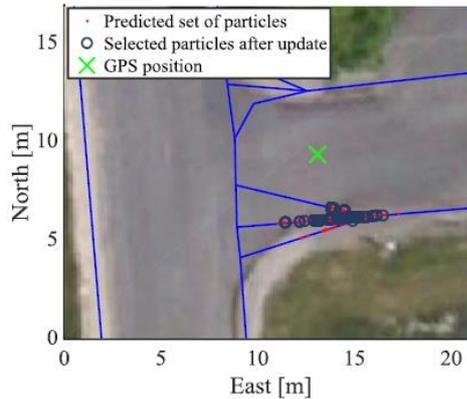


Figure 73: Les particules rouges explorent le graphe. Celles qui ont un poids important (entourée en bleu foncé) sont celles qui se trouvent sur le segment dont l'orientation est la plus proche du cap mesuré et qui sont les plus proches de la position GNSS (croix verte) [113]

V.2.2.1 Bilan sur l'utilisation d'un filtre particulaire pour la fusion d'un graphe et autres capteurs

Le déploiement d'un filtre particulaire est adapté pour explorer un graphe de navigation. Les différentes hypothèses sont prises en compte par un seul et même filtre, contrairement au Kalman multi-hypothèses. Par ailleurs, cela ne nécessite pas de linéarisation des modèles. Cependant, un des inconvénients des filtres particuliers est la nécessité de simuler un nombre de particules important afin d'explorer toutes les hypothèses plausibles, ainsi que le besoin de les rééchantillonner à chaque mise à jour du fait d'une dégénérescence inévitable due aux faibles poids assignés aux particules.

V.2.3 Utilisation d'un espace borné avec un filtre de Kalman

Dans [114], les auteurs ont réalisé une comparaison de plusieurs filtres Bayésiens pour la fusion Carte-IMMU-émetteurs radio dans le cadre d'une modélisation par un espace de navigation borné. Dans cette étude, la carte n'est fusionnée avec les autres capteurs qu'en cas d'application d'un filtre particulaire. En effet, l'approche particulaire permet de détruire les particules franchissant les obstacles et de dupliquer les autres, tandis qu'un filtre de Kalman n'apporte pas d'alternative dans le cas où un obstacle est franchi. Le même constat peut être tiré de [68] où les auteurs appliquent le processus de Map-matching en amont de l'application d'un UKF. **Au bilan, le filtre de Kalman ne se prête pas à l'utilisation d'un espace borné.** Le paragraphe suivant traite de la fusion d'un espace borné avec d'autres capteurs au moyen d'un filtre particulaire.

V.2.4 Utilisation d'un espace borné avec un filtre particulaire

Par rapport à la modélisation graphique de l'espace navigable, les approches surfaciques accordent aux particules un nombre de degrés de liberté infini dans un voisinage proche. C'est-à-dire qu'elles ne sont plus contraintes à explorer un nombre de segments fini. Elles ne peuvent toutefois pas franchir les obstacles qui sont exclus de l'espace navigable. Cette approche est avantageuse par rapport aux graphes construits sous forme de maillage dans le sens où elle assure une meilleure exploration de l'espace navigable.

L'approche surfacique a été exploitée dans le cadre de la navigation automobile avec la prise en

compte de la largeur des routes. A titre d'exemple, dans [115] la route est représentée par une clothoïde à largeur fixe (Figure 74).

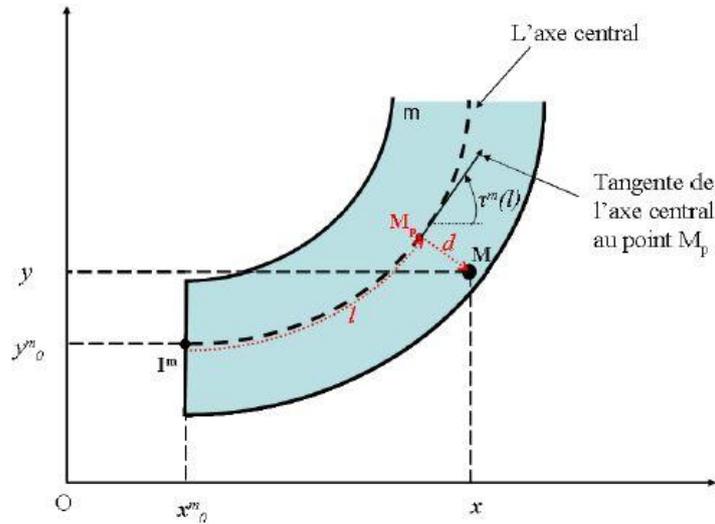


Figure 74: Filtre particulaire appliqué à une route bornée et des capteurs inertiels et GNSS [115]

Le processus de propagation est alors effectué dans un repère de Frénet décrivant l'évolution de chaque particule suivant un vecteur tangent à la clothoïde, à l'aide d'une abscisse curviligne l , ainsi que son déplacement latéral d par rapport au milieu de la route. Cette approche peut être appliquée à la navigation piétonne en adaptant ce principe aux trottoirs et aux couloirs par exemple.

Dans le contexte PDR, le modèle d'évolution adopté pour les représentations surfaciques s'écrit généralement :

$$X_{k+1} = X_k + (s_{k+1} + n_s) \cdot \begin{pmatrix} \sin(\theta_{PDR} + n_\theta) \\ \cos(\theta_{PDR} + n_\theta) \end{pmatrix} \quad \text{E. 114}$$

où n_θ et n_s sont des bruits usuellement Gaussiens qui permettent de disperser les particules en cap et en distance. Les autres variables ont été introduites précédemment.

La principale mesure exploitée dans les approches surfaciques est une mesure binaire permettant de savoir si une particule est sortie de l'espace navigable, c'est-à-dire si elle a franchi un obstacle. De la même manière que la composante latérale est comparée à la largeur de la route afin de détruire les particules qui en sortent dans [115], la mesure considérée dans un milieu indoor consiste à vérifier s'il existe une intersection entre un obstacle matérialisé et localisé dans la carte avec le vecteur de propagation de la particule (Figure 75). Ce vecteur est donné par l'équation :

$$(s_{k+1} + n_s) \cdot \begin{pmatrix} \sin(\theta_{PDR} + n_\theta) \\ \cos(\theta_{PDR} + n_\theta) \end{pmatrix} \quad \text{E. 115}$$

Dans ce cas, le poids affecté à la particule est 0 et elle est détruite dans le processus de rééchantillonnage (Figure 76) [116].

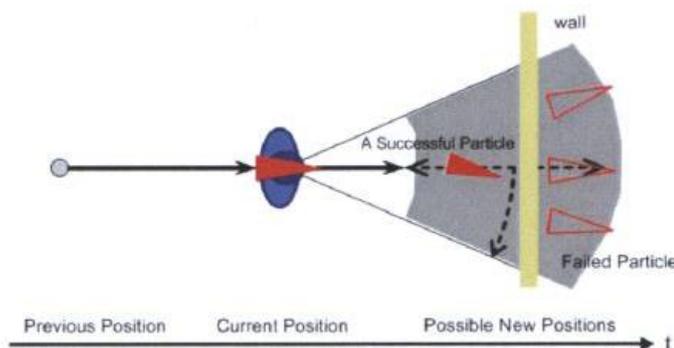


Figure 75: Evitement d'obstacles dans un espace borné à l'aide d'un filtre particulaire [116]

D'autres travaux combinent l'approche surfacique et l'approche graphique en considérant l'orientation des couloirs. Dans le cadre d'application d'un filtre particulaire, on peut citer [117] (Figure 77) où un test permet de reconnaître qu'un piéton marche le long d'un couloir. Ainsi, l'espace borné fournit une pondération binaire aux particules qui leur permet de survivre ou d'être détruites, tandis que le graphe vient affecter aux particules vivantes un poids conforme à leur adéquation avec les orientations des couloirs. En dehors des couloirs, seule l'approche surfacique est gardée.

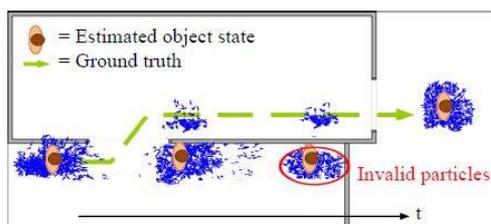


Figure 76: Destruction de particules traversant un mur [116]

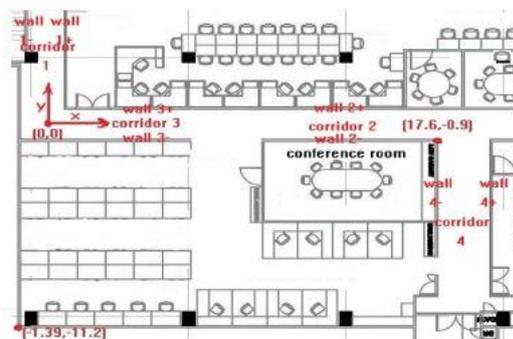


Figure 77: Cartographie des obstacles et prise en compte des orientations des couloirs [117]

V.2.4.1 Bilan sur l'apport d'un espace de navigation borné dans la fusion de la carte avec d'autres capteurs

Cette section permet de tirer deux conclusions. D'une part, seul un filtre particulaire peut traiter le problème de fusion « IMMU-Espace borné de navigation », l'application d'un filtre de Kalman dans ce contexte étant inadaptée. D'autre part, la mesure apportée par un espace de navigation borné se limite à la détection d'obstacles, ce qui permet de détruire les particules improbables dans le processus de fusion. Les approches surfaciques ne permettent pas de compenser la dérive du gyromètre et nous avons vu qu'une approche graphique devait être combinée avec la modélisation surfacique pour ce faire. Néanmoins, dans certaines situations, un graphe peut s'avérer aussi inefficace qu'un espace borné (par exemple dans les zones ouvertes ou lorsque la dérive du gyromètre est trop importante).

Suite à ces différentes conclusions, nous adoptons l'utilisation d'un graphe de navigation car il permet à la fois l'évitement des obstacles mais aussi d'avoir une mesure du cap de marche. Ce choix nous mène également à opter pour un filtre particulaire. Enfin, la problématique liée aux espaces ouverts a été précédemment traitée dans la section III.3 afin de pouvoir profiter du graphe de navigation malgré l'absence d'obstacles.

V.3 Conception du filtre particulaire réalisant le calcul de position

V.3.1 Initialisation

La position initiale est supposée connue. Elle est donnée par le récepteur GNSS sous forme de coordonnées planes (E^1, N^1). Cette position est projetée suivant le(s) arc(s) du graphe le(s) plus

proche(s), ce qui correspond à une simple procédure de map-matching. L'ensemble des particules est dispersé de manière équitable autour des premières positions issues du map-matching. Ce processus est décrit dans la Figure 78 où le graphe est modélisé en bleu, la première position GNSS en vert, et les particules issues du map-matching en rouges.

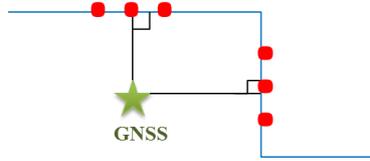


Figure 78 : Initialisation par map-matching d'une position GNSS

Chaque particule a pour identifiant Id , l'identifiant de l'arc sur lequel elle se trouve. Elle a également une abscisse curviligne Dp qui détermine sa position sur l'arc Id et qui vérifie:

$$0 < Dp < L(Id) \quad \text{E. 116}$$

où $L(Id)$ est la longueur de l'arc Id .

V.3.2 Modèle de propagation

V.3.2.1 Orientation

V.3.2.1.1 Le graphe

Pour explorer le graphe depuis les positions initiales, un sens arbitraire δ est associé à chaque particule. Les arcs sont tous orientés d'un nœud d'entrée A vers un nœud de sortie B, ce qui permet d'affecter à chaque particule un sens de déplacement selon la Figure 79.

La direction de l'arc par rapport au Nord géographique et la valeur de la variable δ permettent d'affecter un azimuth à chaque particule. A l'état initial (1), la variable δ a une distribution binomiale pour les valeurs $\{-1, 1\}$ (E. 117):

$$\delta^1 : B(Np, \frac{1}{2}) \quad \text{E. 117}$$

où la valeur $\frac{1}{2}$ est la probabilité d'occurrence de l'événement « $\delta^1 = +1$ » pour un tirage aléatoire.

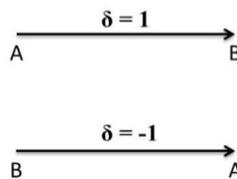


Figure 79 : Orientation des arcs du graphe

Après l'étape d'initialisation, la distribution n'est plus binomiale car le processus de sélection permet de privilégier un sens par rapport à l'autre. La probabilité de faire un demi-tour est fixée arbitrairement à une valeur $p(\text{demi-tour})$. Cela permet de générer deux sous-ensembles :

$$\begin{aligned} \text{Total_Particules} &= \{\text{tout droit}, \text{demi-tour}\} \\ p(\text{tout droit}) &= 1 - p(\text{demi-tour}) \end{aligned}$$

A chaque instant de pas δ est modifié selon :

$$\begin{cases} \delta^t = \delta(Id^t) & \text{si la particule appartient au premier ensemble (tout droit)} \\ \delta^t = -\delta(Id^t) & \text{sinon} \end{cases}$$

Cette modification vient après l'identification de l'arc à l'instant courant et après identification de la précédente direction de marche afin d'imposer un demi-tour à la particule (ou non). Un complément

détaillé est donné en Figure 80.

V.3.2.1.2 Défaut d'alignement entre le capteur et la direction de marche

Le cap PDR correspond à l'orientation du capteur tenu dans la main. Cette orientation est potentiellement différente de la direction de marche. Le vecteur d'état est donc augmenté d'une variable β . Elle correspond au biais entre le cap de marche et l'orientation du capteur. C'est une variable bornée de loi uniforme. (E. 118)

$$\beta : U(-\beta_{\max}, +\beta_{\max}) \quad \text{E. 118}$$

Il convient alors de considérer que le cap de marche est donné par :

$$\theta_{\text{cap de marche}} = \theta_{PDR} + \hat{\beta} \quad \text{E. 119}$$

où $\hat{\beta}$ est l'estimation de β après sélection des particules.

La variable β est dépendante du temps car le mouvement de la main est imprédictible. Elle est donc réinitialisée à chaque instant selon la loi E. 118.

V.3.2.2 Distance

Une fois qu'un arc et un sens sont choisis pour propager une particule, ce qui revient à déterminer une orientation, il reste à déterminer une distance de propagation. Cette dernière correspond en théorie à la longueur de pas s qui est une donnée PDR. Néanmoins, cette donnée a deux erreurs potentielles :

- (1) La longueur de pas est sur/sous-estimée. Nous proposons de la corriger par application d'un facteur d'échelle k qui est intégré au vecteur d'état. Ce facteur est une variable de loi normale initialement d'espérance 1 et d'écart-type σ_k (E. 120):

$$k^1 : \mathbb{N}(1, \sigma_k) \quad \text{E. 120}$$

Ensuite, k est propagé selon le modèle :

$$k^{t+1} = k^t + v \quad \text{E. 121}$$

où v est une variable normale centrée d'écart-type σ_k :

$$v : \mathbb{N}(0, \sigma_k) \quad \text{E. 122}$$

Contrairement au défaut d'alignement, la variable k est censée converger au cours du temps car c 'est une constante par individu.

- (2) Le processus de détection de pas a sur/sous-détekté un pas à l'instant courant. Pour cela une variable α est aussi intégrée au vecteur d'état. Elle peut valoir soit 0, pour corriger une sur-détection, soit 2, pour corriger une sous-détection, soit 1 s'il n'y a pas d'erreur de détection. La distribution de α est arbitrairement imposée. 70% des particules auront une valeur de α valant 1. Les autres particules sont équitablement réparties entre les valeurs 0 et 2.

$$\alpha \in \{0, 1, 2\} \quad \text{E. 123}$$

La variable α est réinitialisée à chaque instant selon la distribution décrite ci-dessus. Son estimation est donnée par un vote majoritaire des particules sélectionnées à chaque mise à jour.

V.3.2.3 Modèle de propagation global

Les particules sont finalement propagées selon un test réalisé sur un variable DU correspondant à :

$$DU = (k^t s^t) \delta^t \alpha^t + n_G + Dp^{t-1} \quad \text{E. 124}$$

où n_G est un bruit blanc Gaussien modélisant les incertitudes sur le graphe (G). L'abscisse curviligne Dp^t est obtenue selon est le signe et la valeur de DU (Figure 80).

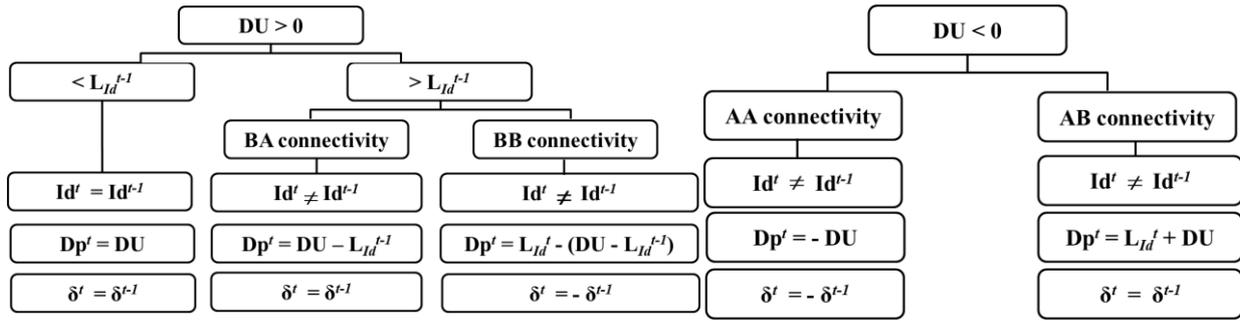


Figure 80 : Test de transition pour le calcul de la variable Dp

Grâce à l'abscisse curviligne Dp et à l'orientation donnée par les variables Id et δ , l'azimut et la position projetée dans le repère de navigation sont connues pour chaque particule. Ces dernières sont respectivement notées θ_{Id} et (E_p, N_p) . Chacune de ces entités a un écart-type qui dépend des

incertitudes sur le graphe et qui sont données par $\sigma_{\theta_{Id}}$ et $\Sigma_p = \begin{pmatrix} \sigma_{E_p} & 0 \\ 0 & \sigma_{N_p} \end{pmatrix}$.

Au bilan, une particule p à l'instant t est définie par le vecteur d'état suivant :

$$[Id, Dp, \delta, k, \alpha, \beta, \omega]_t^p,$$

où :

1. Id est l'identifiant de l'arc,
2. Dp l'abscisse curviligne de la particule suivant cet arc,
3. δ le sens de parcours de l'arc,
4. k le facteur d'échelle qui corrige le modèle de longueur de pas,
5. α est la variable qui corrige le nombre de pas détectés,
6. β le défaut d'alignement entre le capteur et le cap de marche,
7. ω son poids. Ce dernier est initialisé à $\omega^1 = \frac{1}{N_p}$ où N_p est le nombre de particules.

Les variables θ_{Id} et (E_p, N_p) ne font pas partie du vecteur d'état car elles sont redondantes.

V.3.3 Mise à jour

Les observables sont le cap PDR noté θ_{PDR} et éventuellement une position GNSS notée (E_{GNSS}, N_{GNSS}) . Ces deux observables sont qualifiées par une variance qui intervient dans le processus de mise à jour.

V.3.3.1 Orientation

Afin de prendre en compte la dérive du cap PDR, son écart-type est modélisé par l'écart-type d'une marche aléatoire :

$$\sigma_{\theta_{PDR}}^t = \sigma_{\theta_{PDR}}^1 \sqrt{t - t^1} \quad \text{E. 125}$$

où $\sigma_{\theta_{PDR}}^1$ est l'écart-type sur la mesure d'orientation initiale (instant t^1).

Cette modélisation permet alors de séparer les erreurs de dérive de la variable β qui traduit un défaut d'alignement entre le cap de marche et l'orientation du capteur. Par application de ce modèle d'erreur, le calcul de vraisemblance relatif au cap de marche est donné par le modèle de l'équation suivante :

$$\omega^t = \omega^{t-1} \exp\left(-\frac{1}{2} \times \frac{|\theta_{PDR}^t - (\theta_{Id}^t + \beta^t)|^2}{(\sigma_{\theta_{Id}}^t)^2 + \sigma_{\theta_{PDR}}^t{}^2}\right) \quad \text{E. 126}$$

Cette mise à jour de poids est réalisée tout le temps car le graphe est considéré fiable dans tous les espaces (Extérieur, Intérieur, Zones ouvertes).

V.3.3.2 Distance

La calibration de distance nécessite la disponibilité de positions GNSS. L'intérêt de cette calibration est la convergence de la variable k qui est réutilisable en indoor. En revanche, les erreurs de détection de pas ne sont plus réalisées en absence de position GNSS.

V.3.3.2.1 Test de rejet

Comme le récepteur GNSS est un récepteur à haute sensibilité, des signaux de mauvaise qualité (multi-trajets, faible puissance, mauvaise géométrie des satellites visibles) peuvent être exploités pour calculer une position qui n'est toutefois pas précise. Deux indicateurs de qualité sont utilisés pour rejeter ces positions :

1. La puissance du signal. Pour ce faire la moyenne du SNR est calculée à chaque instant :

$$SNR_{moy} = \frac{1}{N_{sat}} \sum_{i=1}^{N_{sat}} SNR_i \quad \text{E. 127}$$

où SNR_i est le rapport signal sur bruit du satellite i .

Le test consiste alors à fixer un seuil de puissance (moyenne) minimale pour la prise en compte de la position GNSS délivrée par le récepteur.

2. La géométrie des satellites visibles. L'indicateur choisi est le HDOP (Horizontal Dilution Of Precision). Sa valeur est également délivrée par le récepteur GNSS.

Le test HDOP consiste également à fixer un seuil minimal en-deçà duquel les positions sont rejetées. Les conditions 1 et 2 sont conjointement nécessaires.

V.3.3.2.2 Calcul de vraisemblance

Si la position délivrée par le récepteur est prise en compte, elle est aussi caractérisée par la matrice de variance suivante :

$$\Sigma_{GNSS} = \begin{pmatrix} \sigma_{E_{GNSS}}^2 & 0 \\ 0 & \sigma_{N_{GNSS}}^2 \end{pmatrix} \quad \text{E. 128}$$

La proximité de la position GNSS et chacune des particules propagées est alors intégrée au calcul de vraisemblance selon le modèle suivant :

$$\omega^t = \omega^{t-1} \exp\left(-\frac{1}{2} \left(\Delta^T \Sigma_{GNSS}^{-1} \Delta + \frac{|\theta_{PDR}^t - (\theta_{Id}^t + \beta^t)|^2}{(\sigma_{\theta_{Id}}^t)^2 + \sigma_{\theta_{PDR}}^t{}^2} \right)\right) \quad \text{E. 129}$$

où

$$\Delta = \begin{bmatrix} |E_P - E_{GPS}| \\ |N_P - N_{GPS}| \end{bmatrix} \quad \text{E. 130}$$

V.3.4 Ré-échantillonnage

Une fois que les particules ont été pondérées, elles sont rééchantillonnées de manière à supprimer celles qui ont un faible poids. N_p particules sont tirées aléatoirement selon la distribution mise à jour de ω . Pour ce faire, les poids sont d'abord normalisés selon l'équation :

$$\bar{\omega}_p^t = \frac{\omega_p^t}{\sum_{i=1}^{N_p} \omega_i^t}$$

E. 131

V.3.5 Intégration des POIs

Les POIs sont intégrés au filtre particulaire pour apporter des mesures de position utilisées comme mises à jour. Leur apport consiste principalement à réinitialiser la position et par conséquent de corriger la distance parcourue sur le graphe de navigation. Ils sont intégrés au filtre selon le pseudo-algorithme suivant :

Initialisation (instant 1, particule p)

Vecteur d'état

$$- [Id, Dp, \delta, k, \alpha, \beta, \omega]_p^1$$

Observables

$$- \theta_{PDR}^1, (E_{GNSS}^1, N_{GNSS}^1)$$

Récurrence (instant >1, particule p)

For $t = Time(First_Step) : Time>Last_Step$ % Boucle temporelle sur le nombre de pas détectés

For $p = 1 : Np$ % Boucle sur les particules

Faire test GNSS et choisir une position (E,N)²⁴

If position GNSS disponible

$$(E, N) = (E_{GNSS}, N_{GNSS})$$

Else

$(E, N) = (E_p^{t-1}, N_p^{t-1}) + StepLength \times (\sin \theta_{PDR}^t, \cos \theta_{PDR}^t)$ % On propage la dernière position estimée selon un modèle simple prenant en compte la longueur de pas et le cap PDR

End

Classification

If $i > Time_Window$ & $i < Time>Last_Step - Time_Window$ % La largeur de fenêtre pour la classification est Time_Window

 Résultat_Classif \leftarrow Classifier le segment $[i - Time_Window, i]$

Faire test détection POI

If Vérifier si la classe définit directement un type de POI

 Résultat_Type_POI $\leftarrow Type(POI)$

Elseif Vérifier si la séquence de mouvement donnée par la classe précédente et la classe courante définissent un type de POI :

 Résultat_Type_POI $\leftarrow Type(POI)$

²⁴ Prédire une position à partir de la dernière position filtrée et du cap PDR en cas de rejet GNSS. Cela sert simplement à faire un calcul de proximité en cas de détection d'un POI

```

Else
    Résultat_Type_POI ← {}
End

Recherche de POI à proximité en cas de détection
If Résultat_Type_POI ≠ {}
    Recherche POI vérifiant :
     $Distance(POI, (E, N)) < R$  % R est le rayon de recherche tolérable pour confirmer un POI

    Si condition vérifiée
     $POI \leftarrow \underset{POI}{\operatorname{argmin}} \left( \begin{array}{l} Distance(POI, (E, N)) < R \ \& \\ Type(POI) = Résultat\_Type\_POI \end{array} \right)$  % Sélectionner le
    POI de type détecté le plus proche de la position propagée (E,N)
    Récupérer position du POI
     $POI\_position = (E_{POI}, N_{POI})$ 

    Map-matcher la position du POI
    Nouvelle_Position ← Map-Match(Graph, POI_position)

    Réinitialiser vecteur d'état
     $[Id, Dp, \delta, k, \alpha, \beta, \omega]_p^t$ 

Else
    Sortir du test
End

Application du filtre particulière comme décrit sans POI.
End
End

```

Chapitre VI

VI. EVALUATION EXPERIMENTALE DES PERFORMANCES	103
VI.1 Reconnaissance de mouvement	103
VI.1.1 Descripteurs retenus	103
VI.1.2 Evaluation statistique des résultats de la classification	108
VI.2 Calcul de position	118
VI.2.1 Scénarios d'acquisitions	118
VI.2.2 Evaluation numérique et qualitative des résultats de localisation	120
VI.3 Conclusions	128

VI. Evaluation expérimentale des performances

Remarque concernant les sigles utilisés dans ce chapitre :

*Pour rappel, le codage des noms des classes est explicité à la **Table 4** de la section IV.4.2.2. De même, la nomenclature des descripteurs peut être reprise depuis la section IV.4.4.1, **Table 6**, qui indique sur quel signal un descripteur est calculé, et la section IV.4.5.2, **Table 8**, qui donne la signification de la statistique du descripteur. Par exemple, si le début est `Acc_`, cela signifie que la statistique est calculée sur la norme d'accélération. Si la deuxième partie est `_Var`, ce qui donne `Acc_Var`, alors cela indique la variance de la norme d'accélération.*

VI.1 Reconnaissance de mouvement

Cette partie vise à présenter les résultats obtenus pour la collecte de données détaillée en IV.4.3.2.2. Il s'agit de la base de données établie pour un ensemble de 8 personnes et de 6 bâtiments. Pour rappel, cette base de données a été scindée en deux. D'une part, il y a les données d'apprentissage et de test, et d'autre part, il y a des données de validation qui n'interviennent jamais dans la phase de calcul des modèles de classification.

La sélection des descripteurs est réalisée sur la base des données d'apprentissage, constituée des échantillons calculés pour 4 personnes dans 3 bâtiments différents. Cette base de données fait une taille d'environ 2600 échantillons (i.e. lignes).

L'évaluation des performances de classification est faite sur la base de données de validation. Cette dernière fait une taille d'environ 800 échantillons (i.e. lignes) et correspond aux 4 participants et aux 3 bâtiments restants.

VI.1.1 Descripteurs retenus

Avant d'introduire les descripteurs calculés en entrée des algorithmes de sélection, un prétraitement permet de supprimer les variables redondantes (ex. si le signal est toujours positif, la valeur maximale et le maximum de la valeur absolue sont égaux). Par ailleurs, les descripteurs qui sont constants sont aussi supprimés (ex. la fréquence obtenue par analyse spectrale du signal du magnétomètre, égale à 0 pour toutes les classes).

VI.1.1.1 PCA

L'analyse en composantes principales a été réalisée avec le logiciel Rstudio qui utilise le module `factoextra` [118]. Comme les variables descriptives étaient hétérogènes en termes d'échelle et d'unité, elles ont été normalisées de manière à ce que la moyenne de chaque descripteur soit de 0 et sa variance 1. Nous évitons ainsi de donner de l'importance aux variables en fonction de leur unité. La normalisation des données sert également à éviter de considérer les valeurs moyennes du signal dépendant des environnements où les données ont été collectées (ex. valeur moyenne du champ magnétique mesuré).

La Figure 81 montre que les deux premières composantes principales (PC) ne retiennent que 45 % de la variance totale, ce qui signifie que des composantes (PCs) supplémentaires doivent être considérées. Les 10 premières PCs dont la contribution cumulée à la variance totale dépasse 80% ont été retenues. Les coefficients de corrélation entre chaque PC retenue et les descripteurs initiaux ont été calculés. La Figure 82 et la Figure 83 montrent les valeurs au carré de ces coefficients sous forme de cercles bleus. Plus le bleu est foncé, plus le diamètre du cercle est grand et plus le descripteur en question est bien représenté par la PC. Par conséquent, il a une contribution importante à la variance expliquée par la PC et doit donc être sélectionné.

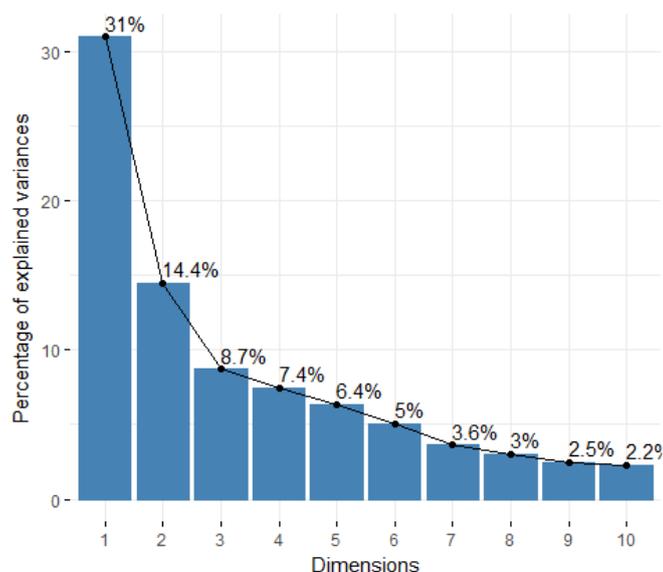


Figure 81 : Variance expliquée par chacun des 10 premiers axes de la PCA

Un contraste peut être noté pour le premier axe de la PCA (Dim1) pour lequel le champ magnétique et la pression ont une faible contribution. Au contraire, les PCs 2 et 3 (Dim2, Dim3) ont une plus grande corrélation avec le champ magnétique et la pression alors qu'elles semblent indépendantes du reste des chaînes de signal. Grâce à cette analyse, une valeur de seuil a été adoptée pour rejeter les descripteurs à faible contribution à la variance totale. Notons qu'il suffisait d'analyser les 3 premières PC car elles recouvrent la totalité des descripteurs calculés. Au bilan, 45 descripteurs ont été retenus. Ils sont donnés en Figure 84.

Les chaînes retenues sont la norme du signal d'accélération ainsi que la vitesse angulaire. Pour l'accélération, la PCA retient à la fois l'enveloppe supérieure et le signal brut. Quant à la pression et au champ magnétique, seuls deux descripteurs sont retenus sur la base du signal brut, à savoir la variance et la hauteur qui sont indépendants de la moyenne du signal. La PCA retient en revanche les gradients de ces deux chaînes de signal, ce qui semble respecter la contrainte d'indépendance aux moyennes du signal et à l'importance de son sens de variation. Dans cette même optique, la moyenne n'a été conservée comme descripteur que pour la vitesse angulaire et l'enveloppe supérieure d'accélération qui sont totalement dépendantes du mouvement.

Suite à cette sélection, un traitement des corrélations entre les différentes variables sélectionnées a été réalisé. Le calcul de la corrélation est fait selon le coefficient de corrélation de Pearson. Au total, 10 descripteurs ont été retenus parmi les 45 sélectionnés. Ils sont donnés en Figure 85.

VI.1.1.2 Score de Fisher (FS)

Le FS est insensible à la normalisation des données. Aussi il a été calculé avec Matlab en utilisant les données non transformées. Les résultats de l'analyse du FS sont donnés en Figure 86. Les barres rouges désignent les descripteurs retenus par seuillage du FS. Ce seuil correspond à la médiane. Seulement 9 descripteurs ont été retenus. On remarque que leur nombre est réduit par rapport aux résultats de la PCA. On constate dans un premier temps l'importance capitale de la pente moyenne de la pression. En effet, cela s'explique physiquement car la valeur absolue de ce descripteur détermine les déplacements verticaux, tandis que son signe détermine le sens du déplacement vertical, ce qui est décisif pour les escaliers, les ascenseurs, et qui permet par conséquent d'isoler les autres classes. Les autres descripteurs retenus sont majoritairement calculés sur la base du champ magnétique et du gradient de pression, mise à part la hauteur de la pression filtrée, qui exprime elle aussi l'ampleur de la variation du signal et donc si un déplacement vertical a lieu ou non. Au bilan, le Score de Fisher privilégie les descripteurs qui rendent compte du contexte spatial du déplacement plutôt qu'au mouvement piéton. En effet, la pression et le champ magnétique varient selon que l'utilisateur se trouve en extérieur ou en intérieur, selon le mobilier et l'architecture des bâtiments, etc. Notons que le champ magnétique permet également de rendre compte des rotations et donc du mouvement piéton.

Suite à cette analyse, il semble que le Score de Fisher est une statistique sélective car ni le signal d'accélération ni le signal du gyromètre n'ont été retenus. En effet, ils ne sont pas de première importance dans la discrimination des classes car ils varient davantage au sein de chaque classe. Ainsi, pour distinguer une phase statique d'un déplacement en ascenseur, la pression est nécessaire. De même, pour distinguer une marche droite d'une montée d'escaliers, c'est également la pression qui le détermine. Ce n'est que par la suite que l'accélération et la vitesse angulaire permettent d'affiner la classification, d'où leur faible FS.

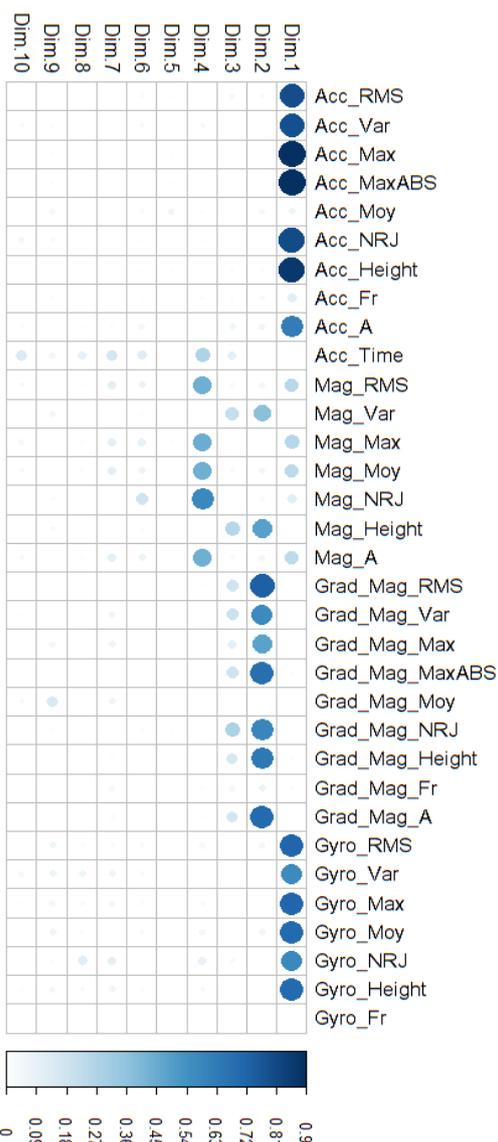


Figure 82 : Coefficients de corrélation au carré des descripteurs avec les axes de la PCA (Première partie)

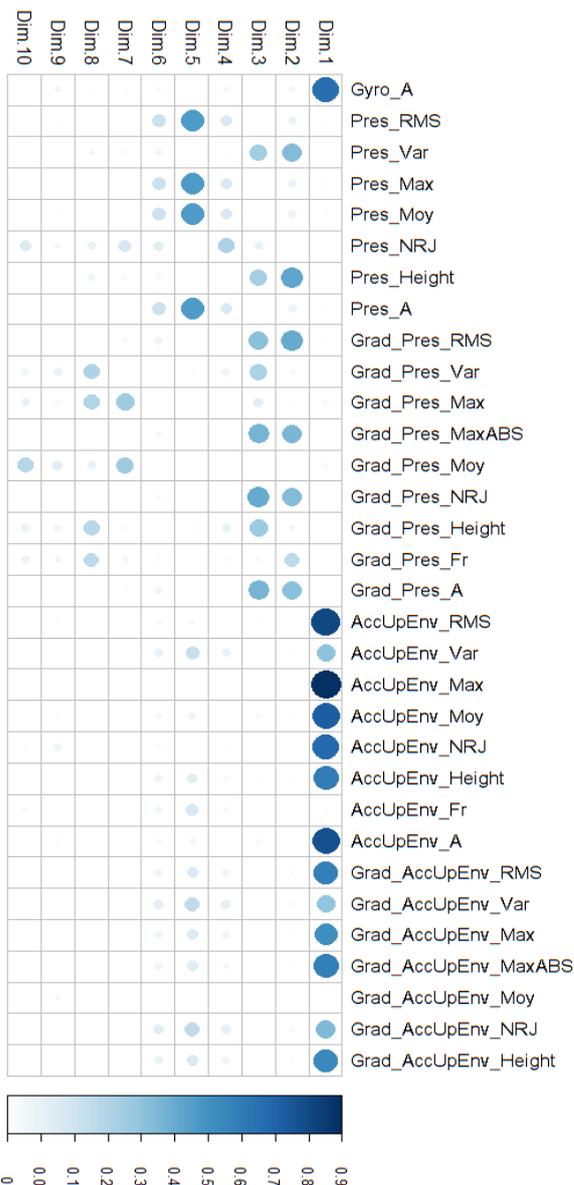


Figure 83 : Coefficients de corrélation au carré des descripteurs avec les axes de la PCA (Deuxième partie)

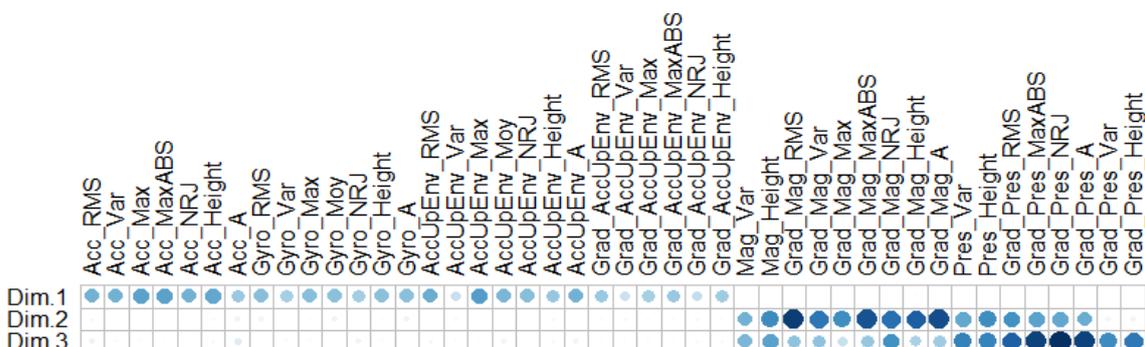


Figure 84 : Descripteurs retenus par seuillage du coefficient de corrélation au carré des descripteurs avec les axes de la PCA

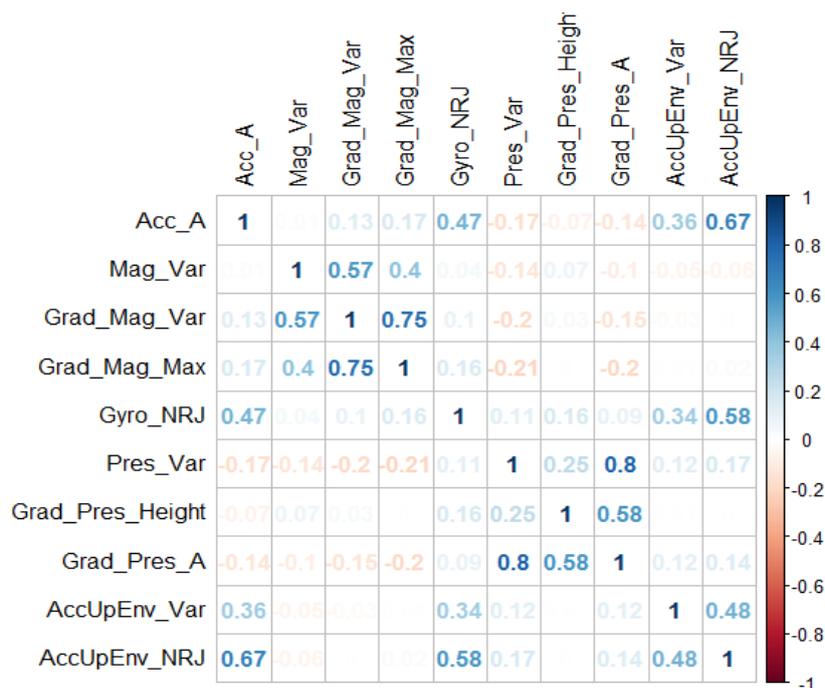


Figure 85 : Descripteurs retenus après réduction des corrélations

VI.1.1.3 Information mutuelle

L'information mutuelle a été calculée avec Rstudio en utilisant les données brutes. Toutefois, c'est une méthode valable pour des variables discrètes (Section IV.3.3.2.3). Les données ont donc été discrétisées avec la fonction « discretize » de la librairie « infotheo » [119]. Les résultats du calcul de l'information mutuelle sont donnés en Figure 87. 29 descripteurs ont été retenus. Les résultats de la sélection s'accordent globalement avec ceux du FS. Le gradient de pression et le champ magnétique sont tous les deux considérés comme des chaînes de signal importantes, malgré quelques différences de sélection au niveau des statistiques choisies (ex. l'énergie du gradient de la pression ou la valeur efficace du champ magnétique). Cependant, l'information mutuelle est aussi élevée pour le signal d'accélération, pour son enveloppe supérieure et pour la vitesse angulaire, ce qui est physiquement justifiable car ces signaux sont corrélés aux classes.

VI.1.1.4 Bilan sur les différentes méthodes de sélection

Il semble d'après ces résultats que l'information mutuelle réalise un bon compromis entre le nombre de descripteurs retenus et la prise en compte de la variable de classification. En effet, la PCA permet de sélectionner un grand nombre de descripteurs en ne tenant compte que de la variance totale au sein des données, le FS permet quant à lui une sélection dure en ne retenant que les variables très déterminantes pour les classes, enfin, l'information mutuelle permet de rejeter les descripteurs dont la variabilité est faible et d'en retenir ceux qui sont corrélés aux classes, bien qu'ils ne soient pas aussi déterminants que les descripteurs retenus par le FS.

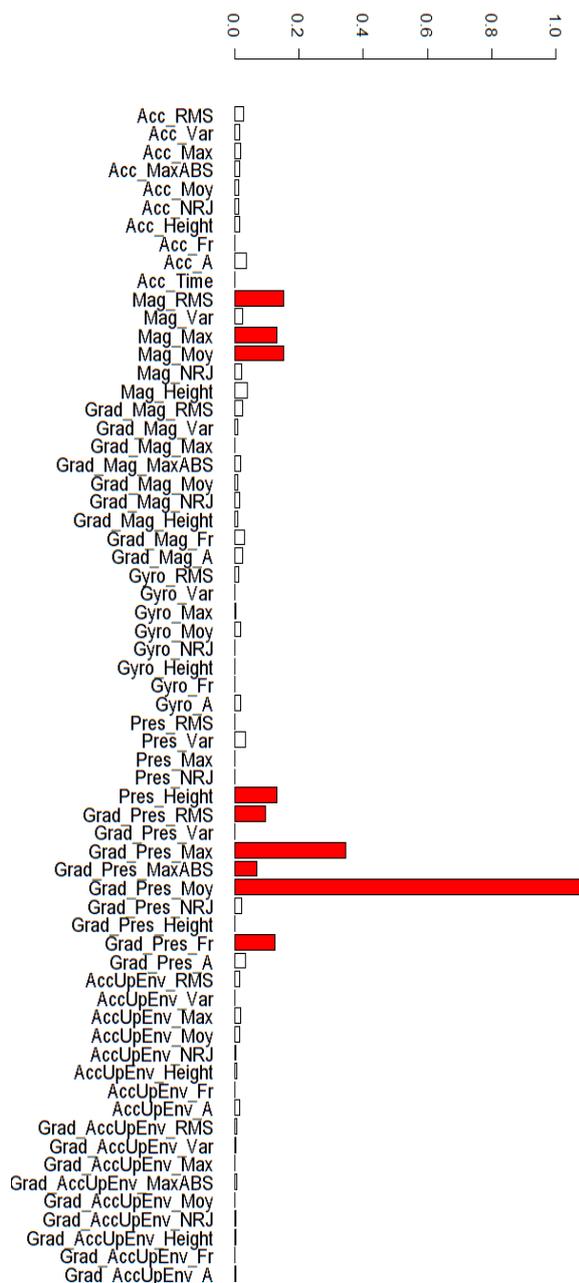


Figure 86 : Score de Fisher pour chaque descripteur

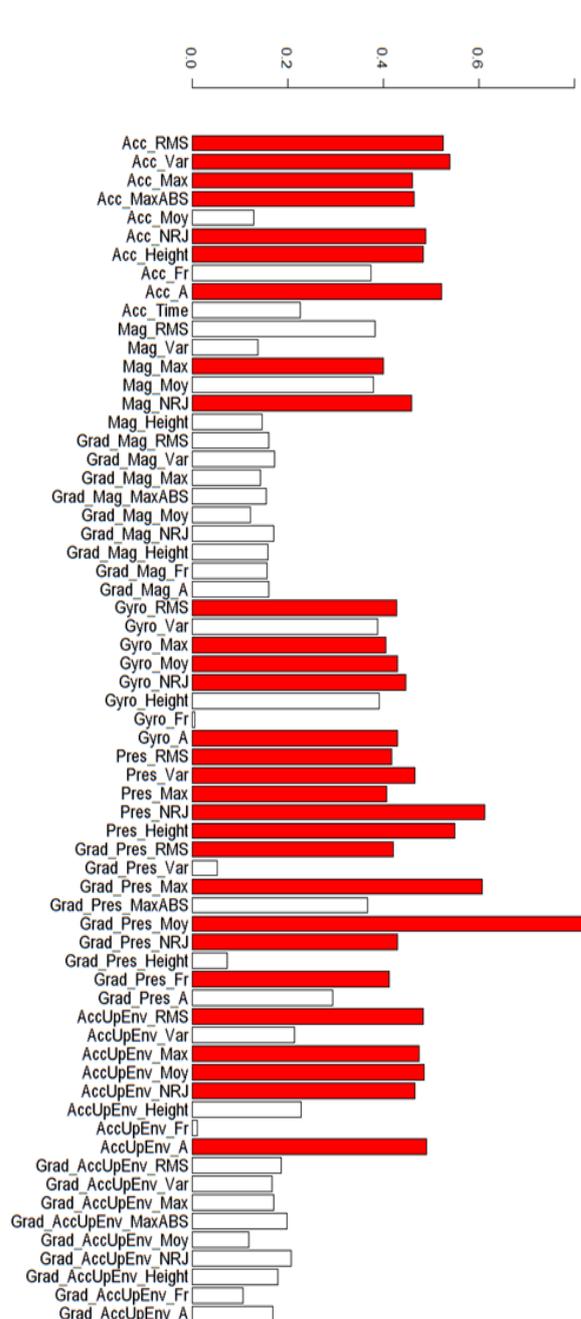


Figure 87 : Information mutuelle pour chaque descripteur

VI.1.2 Evaluation statistique des résultats de la classification

Les tableaux suivants fournissent les mesures de sensibilité et de précision des couples classifieurs/méthode de sélection pour chaque classe ainsi que les précisions globales (OA, toutes classes confondues) obtenues avec chaque modèle de classification et chaque méthode de sélection proposés. Les valeurs maximales sont données en vert et en gras. Deux lignes sont consacrées à chaque modèle. La première donne les mesures de performances pour les classes telles qu'elles ont été créées. La seconde fait la même évaluation en fusionnant deux classes qui n'ont pas de répercussion sur le type de POI détecté :

- Les classes « Do_Entry » et « Do_Exit » correspondants aux portes d'accès aux bâtiments
- Les classes « ED » et « EU » qui correspondent aux ascenseurs

Cela est fait dans un premier temps pour les données test, issues d'un environnement déjà introduit

en apprentissage (VI.1.2.1). Elles ont été sélectionnées aléatoirement depuis la base de données d'apprentissage. La partie VI.1.2.2 s'intéressera ensuite à mesurer ces performances pour les données de validation. La partie VI.1.2.3 comparera les différents classifieurs pour les différentes méthodes de sélection des descripteurs avec des statistiques englobant toutes les classes.

Il y a deux tableaux par méthode de sélection et par groupe de validation (Données test VI.1.2.1, Données de validation VI.1.2.2). Le premier tableau donne les mesures de sensibilité et le deuxième les valeurs de précision. Ce sont deux statistiques calculées relativement à chaque classe. Rappelons que la sensibilité donne le taux d'individus test d'une classe reconnus réellement comme tels par le modèle de prédiction. Cette valeur peut donc nous indiquer empiriquement, et ce pour chacune des classes, le nombre de fois où l'algorithme a échoué à reconnaître un individu test appartenant à la classe courante, ce qui revient tout simplement à évaluer $(1 - \text{sensibilité})$. Du point de vue de la localisation, une faible sensibilité n'engendre pas d'accroissement d'erreur mais simplement une absence de correction. En revanche, les valeurs de précision indiquent le taux d'individus reconnus comme appartenant à la classe courante alors qu'ils appartiennent à une autre : ce sont les faux positifs. Cette situation présente deux potentiels cas de figures du point de vue de la localisation. Soit le faux positif est rejeté car la recherche d'un POI est vaine (Ex. l'algorithme prédit un ascenseur mais il n'y a aucun ascenseur au voisinage de la position actuelle du piéton), dans ce cas l'erreur de prédiction n'entraîne pas d'erreur de localisation, ou alors la recherche d'un POI est positive et cela entraîne une mise à jour (Ex. le piéton marche à côté d'un ascenseur mais il n'est pas dedans, l'algorithme fait une correction où la nouvelle position du piéton est donnée par l'ascenseur), auquel cas l'erreur de classification introduit aussi une erreur de positionnement.

Suite à cette introduction, rappelons que les enjeux sont différents selon les classes et les types d'erreurs. Notre interprétation des résultats s'appuiera sur les trois éléments suivants :

- ***Privilégier la mesure de précision à la mesure de sensibilité***

Notre objectif consiste à réduire l'erreur de localisation et non à l'augmenter. Cela signifie qu'une bonne précision devrait être privilégiée par rapport à une bonne sensibilité. En effet, quand bien même la sensibilité pour une classe serait élevée, si l'algorithme (i.e. classifieur calculé avec les descripteurs retenus par une méthode de sélection) présente beaucoup de faux positifs pour cette classe, donc une faible précision, alors la prédiction qu'il fait pour la classe n'est pas fiable. En revanche, une classe présentant une sensibilité moyenne et une forte précision n'introduirait pas de fausse mise à jour de position.

- ***Se focaliser sur les bas/hauts d'escaliers et les accès aux bâtiments***

Certains POIs ont déjà été traités dans la littérature (les ascenseurs et les coins de couloirs). Nous focaliserons donc une grande partie de notre analyse sur les accès aux bâtiments mais aussi sur les bas et les hauts d'escaliers. La reconnaissance des escaliers a souvent été exploitée dans l'état de l'art pour adapter le mode de déplacement mais jamais, à notre connaissance, pour réaliser une mise à jour de position. De ce point de vue la reconnaissance des phases de marche normale est tout aussi importante que les descentes/montées d'escaliers car les deux sont impliqués dans la définition des POI correspondants.

- ***S'appuyer sur les résultats des données de validation***

Nous nous appuierons davantage sur les résultats obtenus pour les données de validation car ils indiquent la capacité de généralisation des algorithmes. Nous distinguerons les cas de faibles performances par validation croisée, ce qui traduit éventuellement une mauvaise adaptation du modèle de classification aux données d'apprentissage, des cas de bonnes performances en validation croisée et de moins bonnes performances sur des données de validation. Cela traduit une bonne adaptation du modèle aux données d'apprentissage mais une faible capacité de généralisation pour des environnements inconnus. (L'idéal étant d'avoir à la fois de bonnes performances en validation croisée et à la généralisation.)

VI.1.2.1 Résultats de classification pour les données test

De manière globale, les statistiques de performance pour une sélection des descripteurs avec la PCA sont moins bonnes. Ils sont détaillés dans les Table 9 et Table 10. Les valeurs de ces deux tables ne sont pas reprises dans les analyses qui suivent.

VI.1.2.1.1 Reconnaissance de la transition IO

La transition IO nous intéresse particulièrement car sa reconnaissance constitue une contribution importante vis-à-vis de l'état de l'art. Elle est donnée par les deux classes « entrée dans un bâtiment » et « sortie d'un bâtiment ». Ces deux classes permettent en effet de fournir une mesure de position au moment de la transition IO et de réduire l'erreur due à la perte du signal GPS ainsi qu'à la dégradation du réseau de navigation du fait de l'accroissement de la liberté de mouvement du piéton. Pour ce faire, la connaissance du sens de la transition importe peu car le POI reste inchangé, ce qui est une différence notable par rapport à l'existant étant donné que le besoin de reconnaître l'indoor et l'outdoor est supprimé. Néanmoins, les entrées et les sorties ont été séparées dans la nomenclature afin de rechercher une potentielle tendance liée au sens de la transition IO, notamment au niveau du champ magnétique et de la pression. Les résultats détaillés des tableaux ci-dessous montrent que de telles tendances n'ont pas été retrouvées dans les descripteurs retenus, ou du moins qu'elles n'ont pas été suffisantes pour distinguer les entrées des sorties. Sur la base des tableaux présentés ci-dessous, nous détaillons ces résultats dans les paragraphes suivants.

▪ Entrées

La valeur de précision maximale obtenue pour les entrées est de 93.33% (RF, MI, Table 12). La valeur de sensibilité obtenue par ce même algorithme est seulement de 48.26%, ce qui signifie que plus de la moitié des entrées n'ont pas été reconnues comme telles. En revanche, la sensibilité maximale obtenue pour les entrées est de 65.52% (SVM, MI, Table 11), qui reste assez faible et qui correspond à une valeur de précision de 76.00% (Table 12). Nous constatons que l'algorithme qui assure la meilleure performance de prédiction des entrées (RF, MI) en ignore plus de la moitié, en l'occurrence l'algorithme RF avec calcul de l'information mutuelle. Nous constatons également que la sensibilité maximale obtenue pour cette classe, avec l'algorithme SVM et calcul de l'information mutuelle, reste faible (65.52%) tout en n'assurant pas une grande performance de prédiction.

▪ Sorties

En ce qui concerne les sorties, la précision maximale est obtenue pour l'algorithme (SVM, MI, Table 12) avec une valeur de 77.78%. La sensibilité équivalente est de 53.85%. L'algorithme qui assure la meilleure sensibilité est Random Forest par calcul de l'information mutuelle (RF, MI, Table 11) avec une valeur de 92.31%. En revanche, il présente une précision de 63.15% pour la même classe. Au bilan, la même conclusion qu'au paragraphe précédent peut être tirée, c'est-à-dire qu'il n'est pas possible d'avoir une grande performance de prédiction (forte précision) des sorties et en même temps d'en reconnaître un grand nombre (forte sensibilité).

Ces résultats confortent l'analyse de signal qui a précédé le calcul des descripteurs et qui n'a pas été concluante quant à la présence de signature spécifique aux classes « entrée/sortie dans un/d'un bâtiment ».

▪ Fusion des entrées et des sorties

En fusionnant les entrées et les sorties, nous avons supprimé ces deux classes et créé une nouvelle classe correspondant tout simplement à la transition IO sans nous soucier de son sens. Les lignes paires de chaque tableau donnent ainsi les précisions relatives de cette nouvelle classe. Si elles sont considérablement améliorées par rapport à celles des deux classes originales, cela signifie qu'une part importante des erreurs relatives des deux classes « entrées/sorties dans un/d'un bâtiment » proviennent de leur confusion mutuelle, mais pas de la reconnaissance de la transition IO en tant que telle. Dans ce cas, la possibilité de détecter correctement les POI correspondants aux accès des bâtiments est confirmée. Dans le cas contraire, cela signifie que les accès ont été confondus avec d'autres classes qui fournissent potentiellement d'autres types de POI, ce qui contrarie notre objectif de mise à jour par détection des accès aux bâtiments.

La meilleure précision obtenue pour cette nouvelle classe est de 100% et elle a été obtenue avec 4 algorithmes différents (SVM-MI, RF-MI, Table 12, et SVM-FS, RF-FS, Table 14). Parmi ces 4 algorithmes, une sensibilité maximale de 96.36% a été obtenue avec l'algorithme RF-MI (Table 11). Elle est suivie par une sensibilité de 78.18% pour l'algorithme SVM-MI, ce qui est déjà assez faible par rapport à la performance du RF-MI. Nous en retenons que l'algorithme Random Forest utilisé après sélection des descripteurs par calcul de l'information mutuelle est fiable pour la prédiction et la détection des accès aux bâtiments. Cette hypothèse sera revérifiée lors des analyses des résultats obtenus avec les données de validation.

VI.1.2.1.2 Reconnaissance des escaliers

▪ Descentes Escaliers

La plus forte précision pour les descentes d'escaliers est de 97.87% (SVM-MI, Table 12). Elle est suivie d'une valeur de 96.84% (RF-MI, Table 12). Les valeurs de sensibilité correspondantes sont respectivement 97.87% et 97.87%, c'est-à-dire égales. Nous en retenons que ces deux algorithmes sont fiables pour reconnaître les descentes d'escaliers.

▪ Montées d'escaliers

La plus forte précision pour les montées d'escaliers est de 98.13% (RF-MI, Table 12). Elle est suivie d'une valeur de 97.06% (SVM-MI, Table 12). Les valeurs de sensibilité correspondantes sont respectivement 97.22% et 91.67% (Table 11). Nous en retenons que ces deux algorithmes sont fiables pour reconnaître les descentes d'escaliers.

VI.1.2.1.3 Marche normale

A ce stade nous avons confirmé l'adaptation des algorithmes RF-MI et SVM-MI pour la reconnaissance des classes les plus importantes dans cette étude. Nous ne procédons plus par recherche des valeurs maximales des statistiques de performances mais simplement par vérification que ces statistiques sont acceptables pour les deux algorithmes retenus.

Les valeurs de précision pour la marche normale sont de 98.71% pour RF-MI et de 94.81% pour SVM-MI. Les valeurs de sensibilité correspondantes sont respectivement 98.71% et 99.22%. Ces valeurs démontrent que la marche normale est aussi bien reconnue par les algorithmes considérés.

VI.1.2.1.4 Ascenseurs

Les valeurs de précision pour les montées d'ascenseurs sont de 100% pour RF-MI et de 97.87% pour SVM-MI. Les valeurs de sensibilité correspondantes sont toutes les deux de 100%. Pour les descentes d'ascenseurs, la précision est de 100% pour les deux algorithmes, et les sensibilités 100% pour RF-MI de 97.73% pour SVM-MI. La fusion des montées et des descentes nous amène à une précision de 100% et une sensibilité de 100% pour les deux algorithmes.

VI.1.2.1.5 Coins de couloirs

Les valeurs de précision pour les coins de couloirs sont de 91.67% pour RF-MI et de 95.45% pour SVM-MI. Les valeurs de sensibilité correspondantes sont respectivement de 100% et 95.45%.

Ces résultats montrent que les algorithmes SVM et RF ainsi que la sélection des descripteurs par calcul de l'information mutuelle permettent de calculer des modèles de prédiction qui présentent des performances élevées en validation croisée.

VI.1.2.1.6 Liste des Tables des statistiques de performances pour les données test

▪ PCA

Classifieur \ Classe	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	22.73	41.38	11.54	62.77	40.91	52.17	89.66	54.63	69.71
	~	56.63	~	90.00	~	~			76.98

SVM	0	55.17	61.54	69.15	61.36	50.00	99.48	70.37	80.42
	~	76.36		~	98.89		~	~	86.90
RF	36.36	55.17	53.85	80.85	79.55	56.52	98.71	69.44	83.60
	~	74.55		~	100		~	~	88.89

Table 9 : Valeurs de sensibilités et de précisions globales (%) pour la sélection par PCA

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	18.52	32.43	25.00	55.66	36.73	58.54	88.97	62.77	69.71
	~	63.27		~	90.00		~	~	76.98
SVM	ND	72.73	72.73	87.84	54.00	57.50	86.32	74.51	80.42
	~	95.45		~	98.89		~	~	86.90
RF	88.89	80.00	60.87	82.61	62.50	74.29	89.46	79.79	83.60
	~	95.45		~	98.90		~	~	88.89

Table 10 : Valeurs de précisions et de précisions globales (%) pour la sélection par PCA

▪ Information Mutuelle

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	54.54	44.83	53.85	96.81	20.45	93.47	54.26	92.59	65.08
	~	72.73		~	56.96		~	~	66.79
SVM	95.45	65.52	53.85	97.87	97.73	100	99.22	91.67	94.97
	~	78.18		~	100		~	~	96.43
RF	100	48.26	92.31	97.87	100	100	98.71	97.22	96.43
	~	96.36		~	100		~	~	98.41

Table 11 : Valeurs de sensibilités et de précisions globales (%) pour la sélection par calcul de l'information mutuelle (MI)

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	92.31	16.46	24.14	49.46	100	100	99.06	63.29	65.08
	~	29.20		~	100		~	~	66.79
SVM	95.45	76.00	77.78	97.87	100	97.87	94.81	97.06	94.97
	~	100		~	100		~	~	96.43
RF	91.67	93.33	63.15	96.84	100	100	98.71	98.13	96.43
	~	100		~	100		~	~	98.41

Table 12 : Valeurs de précisions et de précisions globales (%) pour la sélection par calcul de l'information mutuelle (MI)

▪ Score de Fisher

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	45.45	27.59	73.08	58.51	20.45	50.00	37.98	74.07	46.43
	~	92.73		~	38.89		~	~	51.32
SVM	63.64	34.48	53.85	92.55	90.91	89.13	96.12	92.59	89.68

	~	55.56	~	90.00	~	~			90.48
RF	72.73	44.83	80.77	93.62	93.18	91.30	96.64	95.37	92.33
	~	81.82	~	92.22	~	~			93.78

Table 13 : Valeurs de sensibilités et de précisions globales (%) pour la sélection par calcul du Score de Fisher (FS)

Classifieur \ Classe	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	16.12	4.80	17.43	49.11	81.82	95.83	91.30	72.73	46.43
	~	18.48	~	100	~	~	~	~	51.32
SVM	60.87	90.91	73.68	91.58	88.89	97.62	89.21	96.15	89.68
	~	100	~	~	93.10	~	~	~	90.48
RF	88.89	92.86	67.74	89.80	89.13	93.33	94.92	93.63	92.33
	~	100	~	~	91.21	~	~	~	93.78

Table 14 : Valeurs de précisions et de précisions globales (%) pour la sélection par calcul du Score de Fisher (FS)

VI.1.2.2 Résultats obtenus pour les données de validation

Le même procédé qu'en VI.1.2.1 est mis en œuvre pour les données de validation. Cette validation nous donne un aperçu sur la généralisation des modèles calculés et sur leur capacité de prédiction sur des données issues d'environnements inconnus.

VI.1.2.2.1 Reconnaissance de la transition IO

La partie précédente a montré qu'il n'était pas possible de distinguer les entrées des sorties. Nous traiterons donc uniquement le cas fusionné (lignes paires des tableaux pour la classe fusionnée). Nous nous intéresserons également dans un premier temps aux deux algorithmes retenus par analyse des résultats de la validation croisée, à savoir SVM et RF avec calcul de l'information mutuelle.

▪ Fusion des entrées et des sorties

Les précisions obtenues pour la transition IO sont de 100% pour l'algorithme SVM-MI mais aussi RF-MI (Table 18). Les valeurs de sensibilité équivalentes sont respectivement de 95.83% pour RF-MI et de 88.54 pour SVM (Table 17). L'algorithme RF-MI assure donc de meilleures performances pour la reconnaissance de la transition IO sur les données de validation.

VI.1.2.2.2 Reconnaissance des escaliers

▪ Descentes Escaliers

Les précisions obtenues pour les descentes d'escaliers sont de 85.19% pour RF-MI et de 81.10% pour SVM-MI. Les valeurs de sensibilité équivalentes sont respectivement de 97.87% et de 94.33%. On remarque que les valeurs de précision sont nettement plus faibles que celles obtenues pour des signaux issus d'environnement connus. Néanmoins ces valeurs restent acceptables et mettent en avant l'algorithme RF par rapport à l'algorithme SVM en ce qui concerne la descente des escaliers.

▪ Montées d'escaliers

Les précisions obtenues pour les montées d'escaliers sont de 83.85% pour RF-MI et de 97.41% pour SVM-MI. Les valeurs de sensibilité équivalentes sont respectivement de 60.89% et de 84.36%. Cela traduit une meilleure efficacité de l'algorithme SVM-MI à reconnaître les montées d'escaliers. En effet, il y a environ 40% d'omissions pour les montées d'escaliers par l'algorithme RF-MI. On constate par ailleurs que les erreurs d'omission sont plus importantes pour les montées d'escaliers que pour les descentes (valeurs de sensibilité). Ce constat a été fait ailleurs dans la littérature [120]. Cette dernière étude montre notamment qu'il est plus probable de confondre une montée d'escaliers avec une marche normale, tout comme il est plus probable de confondre une descente d'escaliers avec une course à pieds. Néanmoins, les valeurs de précision sont acceptables pour les deux algorithmes, ce qui

laisse penser qu'ils peuvent être utilisés sans engendrer d'erreurs de positionnement.

VI.1.2.2.3 Marche normale

Les précisions obtenues pour la marche normale sont de 74.13% pour RF-MI et de 84.53% pour SVM-MI. Ces valeurs montrent que l'algorithme SVM-MI se généralise mieux quant à la reconnaissance de la marche normale. Sa sensibilité est de 84.36%, ce qui est également une valeur acceptable. Nous pensons que la marche normale est caractérisée par une grande variance intra-classe car elle dépend de plusieurs paramètres liés à la motricité de l'utilisateur, sa cadence de marche, les différents types de terrains et leur impact sur le signal, etc. Par ailleurs, d'un point de vue physique, il est difficile de distinguer les terrains accidentés à pente variable des cages d'escaliers à faible pente, d'où les confusions entre les deux.

VI.1.2.2.4 Ascenseurs

La précision obtenue avec RF-MI pour les descentes d'ascenseurs est de 98.44% et avec SVM-MI de 100%. Les valeurs de sensibilité équivalentes sont respectivement de 96.92% et de 73.85%. Cette dernière valeur indique que l'algorithme SVM-MI a omis 26% des descentes d'ascenseurs sur les données de validation. Les statistiques de RF-MI restent quant à elles assez proches des valeurs obtenues sur les données test.

Les précisions obtenues pour les montées d'ascenseurs de 97.73% pour RF-MI et de 95.83% pour SVM-MI. Les valeurs de sensibilité équivalentes sont de 70.49% et de 75.41%. Ces résultats montrent une bonne puissance de prédiction pour les deux algorithmes et une dégradation de la sensibilité par rapport aux données test. Cela indique qu'entre 25 et 30% des montées d'ascenseurs ont été omises par les deux algorithmes.

Nous en concluons que l'apprentissage de la classe correspondant aux ascenseurs nécessite une collecte de signal plus conséquente (ici seulement un seul ascenseur a servi pour l'apprentissage et le second pour la validation).

VI.1.2.2.5 Coins de couloirs

Les précisions obtenues pour les coins de couloirs sont de 89.47% pour RF-MI et de 94.44% pour SVM-MI. Les valeurs de sensibilité équivalentes sont toutes les deux de 94.44%. Cela indique notamment une meilleure généralisation de l'algorithme SVM aux données de validation quant aux coins de couloirs.

Au terme de cette analyse, il semble que les algorithmes SVM et RF avec sélection par calcul de l'information mutuelle se généralisent de manière suffisante aux données issues d'un environnement nouveau. Des dégradations sont toutefois notées pour certaines classes, comme la marche normale, les montées d'ascenseurs ou encore les coins de couloirs. Ces dégradations sont plus ou moins importantes selon la classe et l'algorithme considéré. L'analyse que nous avons menée est basée sur des statistiques relatives. Ces dernières sont insensibles à la distribution des classes qui n'est pas équitable dans notre cas d'étude. Nous proposons d'analyser des statistiques englobant toutes les classes à la section suivante. La précision globale est en effet biaisée par la distribution des classes. Nous ajoutons deux statistiques globales (les macro-moyennes de précision et de sensibilité) qui permettent de prendre en compte ce déséquilibre de distribution pour conclure quant aux modèles calculés et à leurs performances sur les données test et les données de validation.

VI.1.2.2.6 Liste des Tables des statistiques de performances pour les données de validation

- PCA

Classe / Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	5.56	48.98	14.89	68.09	46.15	31.15	82.70	32.40	54.08
	~	78.13		~	78.57		~	~	65.87
SVM	0	46.94	29.79	58.87	26.15	50.82	99.58	53.63	62.74

	~	63.54	~	74.60	~	~			71.52
RF	22.22	44.90	34.04	53.19	30.77	75.41	89.87	60.33	63.24
	~	75.00	~	94.44	~	~			74.15

Table 15 : Valeurs de sensibilités et de précisions globales (%) pour la sélection par PCA

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	6.25	33.33	21.21	49.49	50.85	47.50	70.76	54.72	54.08
	~	71.43	~	100	~	~			65.87
SVM	ND	60.53	48.28	54.61	56.67	48.44	67.24	72.18	62.74
	~	91.04	~	100	~	~			71.52
RF	66.67	53.66	36.36	70.75	62.50	52.27	73.70	56.54	63.24
	~	84.71	~	99.17	~	~			74.15

Table 16 : Valeurs de précisions et de précisions globales (%) pour la sélection par PCA

▪ **Information Mutuelle**

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	50	16.32	44.68	97.87	44.61	85.24	47.67	86.59	65.87
	~	73.96	~	65.08	~	~			71.26
SVM	94.44	59.18	63.83	94.33	73.85	75.41	99.16	84.36	86.44
	~	88.54	~	76.19	~	~			89.96
RF	94.44	46.93	57.44	97.87	96.92	70.49	89.45	60.89	79.30
	~	95.83	~	85.05	~	~			84.82

Table 17 : Valeurs de sensibilités et de précisions globales (%) pour la sélection par calcul de l'information mutuelle (MI)

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	100	15.09	28.77	61.88	96.67	100	83.70	69.82	65.87
	~	56.35	~	98.80	~	~			71.26
SVM	94.44	65.91	71.42	81.10	100	95.83	84.53	97.41	86.44
	~	100	~	100	~	~			89.96
RF	89.47	56.10	52.94	85.19	98.44	97.73	74.13	83.85	79.30
	~	100	~	100	~	~			84.82

Table 18 : Valeurs de précisions et de précisions globales (%) pour la sélection par calcul de l'information mutuelle (MI)

▪ **Score de Fisher**

Classe Classifieur	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	66.67	59.18	57.45	76.60	24.62	49.18	22.78	68.72	50.06
	~	93.75	~	38.10	~	~			54.58
SVM	61.11	38.78	27.66	87.52	55.38	59.02	93.25	94.41	78.67

	~	54.17	~	57.14	~	~			81.18
RF	72.22	69.39	42.55	99.29	55.38	70.49	82.70	94.97	81.81
	~	96.88	~	62.70	~	~			86.70

Table 19 : Valeurs de sensibilité et de précisions globales (%) pour la sélection par calcul du Score de Fisher (FS)

Classifieur \ Classe	Co	Do_Entry	Do_Exit	DS	ED	EU	NW	US	OA
NN	13.48	14.50	30.00	78.26	94.12	93.75	66.67	82.00	50.06
	~	31.03	~	97.96	~	~			54.58
SVM	84.62	48.72	34.21	90.37	100	100	71.29	88.95	78.67
	~	67.53	~	100	~	~			81.18
RF	100	55.74	55.56	95.54	100	100	89.91	79.44	81.81
	~	95.88	~	100	~	~			86.70

Table 20 : Valeurs de précisions et de précisions globales (%) pour la sélection par calcul du Score de Fisher (FS)

VI.1.2.3 Statistiques globales

Dans les sections précédentes, deux algorithmes ont été sélectionnés par analyse des résultats relatifs aux classes les plus importantes au vu de notre contribution à l'état de l'art. Ici, trois statistiques globales sont présentées afin de juger des performances des algorithmes indépendamment des classes. La première est la précision globale, la deuxième est la macro-moyenne de la sensibilité, et la dernière est la macro-moyenne de la précision. Ces deux dernières tiennent compte de la distribution des classes (IV.3.1.3.2).

La Figure 88 montre l'ensemble de ces statistiques. A gauche, ce sont les résultats obtenus sur les données test, tandis qu'à droite il s'agit des statistiques obtenues pour les données de validation. Chaque ligne correspond à une statistique.

Sur les données test, l'algorithme RF-MI présente une meilleure performance vis-à-vis de toutes les statistiques calculées. Il est suivi par l'algorithme SVM-MI. En revanche, sur les données de validation, l'algorithme SVM-MI présente de meilleurs résultats, et ce pour toutes les statistiques calculées. Cela montre que si toutes les classes sont d'importances égales, alors l'algorithme SVM-MI présente de meilleures capacités de généralisation que RF-MI. Notons que les statistiques obtenues avec l'algorithme RF-MI restent satisfaisantes (>80%).

Les résultats obtenus avec le réseau de neurones artificiel ne sont pas satisfaisants. Nous pensons qu'un réseau plus complexe, avec plusieurs couches et un paramétrage plus minutieux, devrait assurer de meilleures performances notamment au niveau de la validation croisée.

Enfin, l'algorithme SVM-PCA a omis une classe, ce pourquoi ses macro-moyennes de précision et de sensibilité sont absentes. Cela laisse penser qu'un descripteur important aurait été rejeté par l'analyse PCA. Les statistiques obtenues pour l'algorithme RF-PCA confortent également cette hypothèse car elles sont nettement inférieures à celles obtenues pour RF-MI et RF-FS.

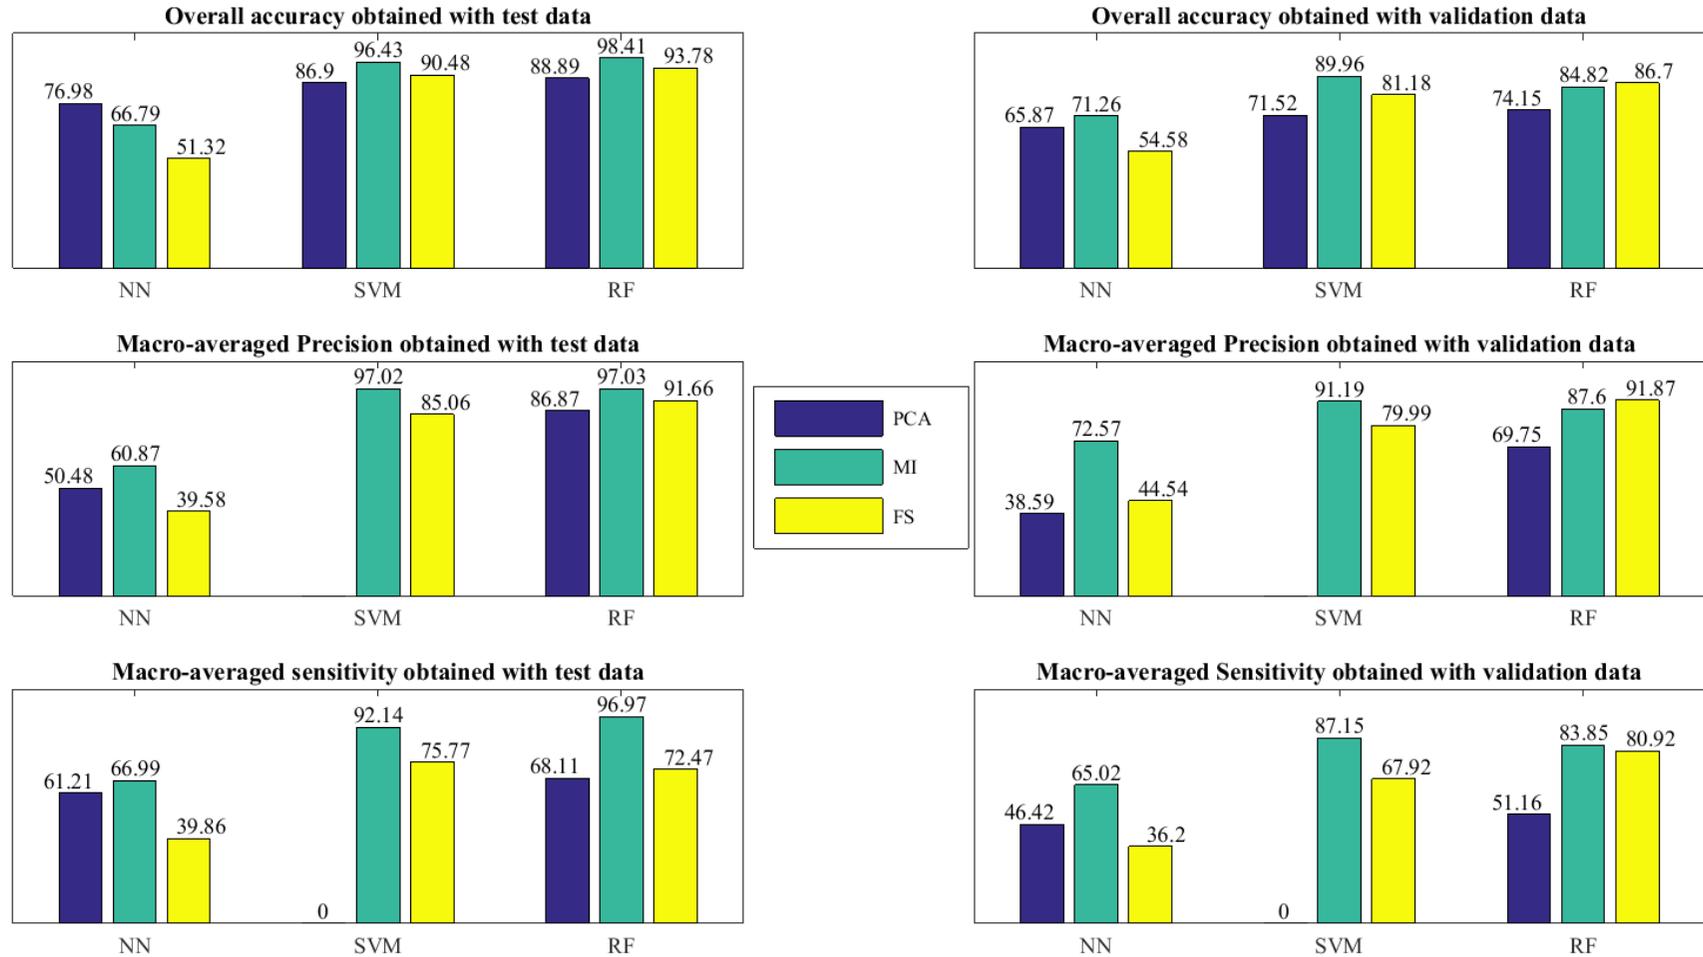


Figure 88 : Valeurs de précision globale et de macro-moyennes de précision et de sensibilité pour chaque algorithme

VI.2 Calcul de position

VI.2.1 Scénarios d'acquisitions

VI.2.1.1 Scénario 1: Acquisition au sein de l'IFSTTAR avec passage par des POIs

Ce scénario vise à tester l'efficacité de la détection de POI sur un trajet court. Cette détection est surtout intéressante au moment de la transition IO et en indoor car il n'y a pas de mesure de position absolue. L'acquisition est faite sur une longueur approximative de 300m de marche débutant en extérieur. Elle comprend le passage par des hauts et des bas d'escaliers, par des accès aux bâtiments et par des coins de couloirs. Ces points d'intérêts ont été stockés dans une base de données et sont affichés en Figure 90. Ils sont représentés par les ronds pleins. Le trajet planifié pour la collecte de signal est donné en rouge. Il s'agit ici davantage de tester la fréquence des mises à jour de position et donc de corrections de distance. La correction de la dérive est quant à elle gérée par le graphe de navigation.

VI.2.1.2 Scénario 2: Acquisition au sein de l'IFSTTAR sans passage par des POIs

Le second scénario correspond à environ 1 km de marche avec un début d'acquisition en extérieur, un passage en indoor et une sortie en extérieur (Figure 91, Figure 92). L'acquisition s'est déroulée avec le capteur ULISS tenu en main dans un mode Texting (Figure 89). Cette acquisition est réalisée dans le but de tester l'efficacité de la fusion d'un graphe de navigation couvrant l'indoor et l'outdoor avec les mesures inertielles et magnétique ainsi que les positions GNSS délivrées par le récepteur. Cette expérimentation sert par ailleurs à mettre en avant les possibilités de calibration du modèle de navigation mais aussi la difficulté du passage IO à cause d'un cumul d'erreurs lié à la perte de GNSS et l'absence d'a priori sur le mouvement piéton. C'est la raison pour laquelle la transition IO a été intégrée au processus de détection des POIs.



Figure 89 : Acquisition dans un mode Texting

VI.2.1.3 Scénario 3: Centre commercial Atlantis (zone indoor non-contrainte par les obstacles)

Trois expérimentations ont été menées par trois personnes différentes (1 femme, 2 hommes) selon deux scénarios d'acquisition dans un centre commercial à Nantes. Cette acquisition diffère du scénario 2 par le court trajet en outdoor et par une plus grande phase de marche en indoor. Elle sert à démontrer l'apport d'une nouvelle architecture de graphe de navigation permettant de limiter les erreurs en zone de transition IO mais aussi en zone indoor non contrainte par les obstacles.

Les trajets sont d'environ 1.5km avec le capteur ULISS tenu en main. Deux personnes ont réalisé l'acquisition dans un mode Texting selon le trajet de la Figure 93, la troisième a réalisé l'acquisition dans les deux modes Texting et Swinging selon le trajet de la Figure 94.



Figure 90 : Scénario d'acquisition avec des POI



Figure 91 : Trajet planifié en rouge



Figure 92 : Zoom sur le début et la fin de l'acquisition

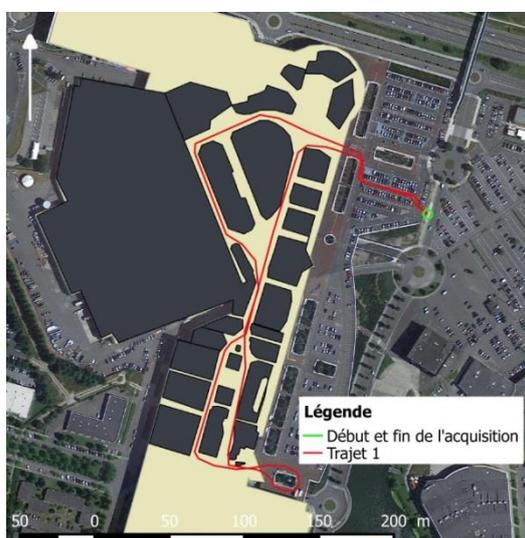


Figure 93 : Scénario 1

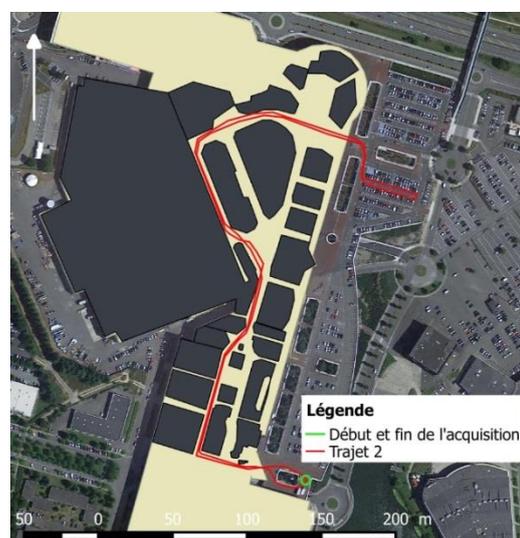


Figure 94 : Scénario 2

VI.2.1.4 Trajectoires de référence

Les trajectoires de référence sont issues d'un post-traitement GNSS en mode différentiel (DGNSS) avec le logiciel RTKLib 2.4.2 [121]. Le mode différentiel utilise au moins deux récepteurs GNSS, une station de base fixe dont les coordonnées sont précisément connues (Ex. réseau RGP) et un récepteur mobile. Les positions calculées sont obtenues avec des précisions allant du centimètre en zone dégagée au décimètre dans les zones plus masquées. Avec un récepteur GNSS bas coût, la précision est dégradée à cause de la qualité de l'antenne GNSS ainsi que de la faible durée des observations car

le récepteur est en mouvement continu : il y a trois nouvelles inconnues de position à chaque instant de calcul. Les conditions sont d'autant plus défavorables en milieu urbain où les trajets multiples sont récurrents. Pour les positions de référence, le signal GNSS est rejeté en fonction des DOP (géométrie des satellites) et des SNR (rapport signal à bruit) afin de limiter l'erreur maximale à 2m.

VI.2.2 Evaluation numérique et qualitative des résultats de localisation

VI.2.2.1 Scénario 1

Ce scénario a été traité avec le modèle simplifié (modèle individuel K-NN avec un seul type de porte) dans l'objectif de démontrer la faisabilité d'une détection en ligne de POIs. Ce processus est transposable au cas du modèle évolué par adaptation des fenêtres de segmentation du signal comme proposé à la section IV.4.6, ce qui constitue une perspective par rapport au travail réalisé au cours de cette thèse.

VI.2.2.1.1 POI détectés

La Figure 95 montre trois trajectoires différentes. La trajectoire verte correspond à un traitement GNSS en mode différentiel, la trajectoire cyan correspond au traitement PDR, et la trajectoire rouge à la trajectoire calculée par filtrage particulaire et par mise à jour avec une détection de POI. Le point de départ correspond à la première position rouge située au Nord de la figure. Le piéton s'est éloigné du bâtiment en se dirigeant vers l'ouest, est monté par des escaliers, est redescendu en direction du bâtiment en passant par deux escaliers différents, il a accédé au bâtiment par l'accès Sud, puis a fait le tour du bâtiment avant d'en sortir et d'arrêter l'acquisition. Les POI détectés sont donnés par les croix jaunes. Il y en a 9 au total. Ils correspondent à 3 bas d'escaliers, 2 hauts d'escaliers, 1 porte d'accès, et 3 coins de bâtiment. Cela signifie que l'algorithme de reconnaissance n'a pas détecté 1 haut d'escaliers, 1 coin de bâtiment et 1 porte d'accès que le piéton a franchie pour quitter le bâtiment.

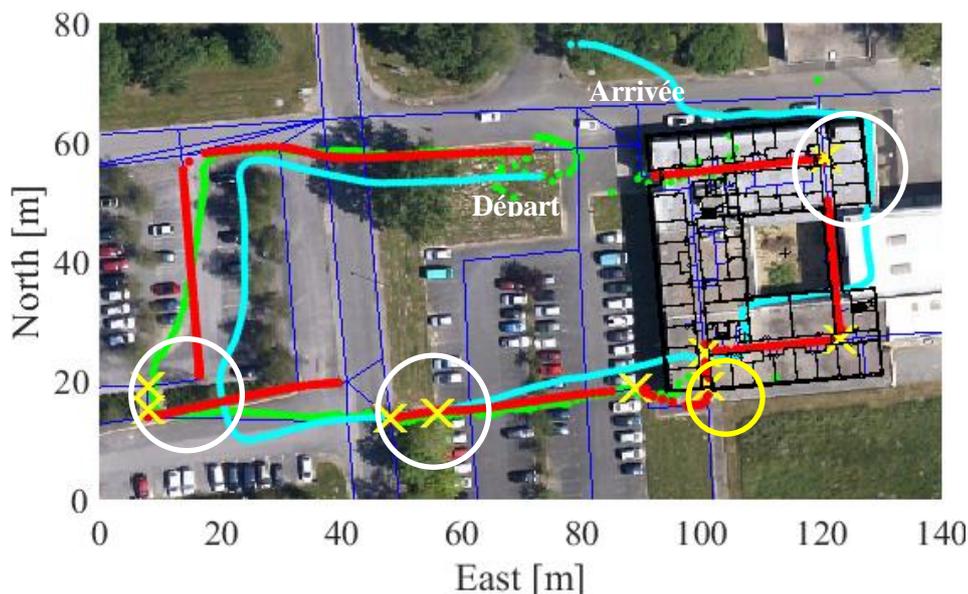


Figure 95 : Trajectoire corrigée avec des POIs régulièrement détectés

VI.2.2.1.2 Correction de distance par détection de POI

VI.2.2.1.2.1 Erreur liée à la construction du graphe

Trois cercles blancs entourent les trois plus grandes corrections de distance par détection de POI sur la Figure 95. La plupart de ces erreurs ne proviennent pas seulement de la non-calibration du modèle de longueur de pas mais surtout de la non-adéquation du graphe de navigation avec le déplacement piéton. Ces déplacements sont reflétés par la trajectoire verte obtenue par GNSS différentiel. Il s'agit souvent de trajets courbes qui ne respectent pas la géométrie des trottoirs ni les tracés du parking, etc. Tant que ces trajets présentent des orientations proches des segments du graphe,

le processus de localisation continue de propager et de sélection des particules sur les segments les plus proches du trajet réel. Dès que la différence des orientations est au-delà d'un seuil donné, les particules sont soit détruites soit bloquées en un nœud, ce qui crée soit un abandon du graphe soit un retard de propagation et donc un saut en position lorsqu'une mise à jour a lieu. Ce scénario s'est produit au premier cercle blanc gauche de la Figure 95.

VI.2.2.1.2.2 Erreur liée à l'estimation d'attitude

La deuxième correction est indiquée par le cercle blanc au milieu de la Figure 95. En effet, ici le graphe comprend bien une hypothèse qui correspond au trajet réel (superposition d'un segment du graphe avec la trajectoire obtenue par GNSS différentiel). Cependant, la trajectoire filtrée suit un autre segment du graphe. Cela s'explique par la qualité d'estimation de l'orientation faite dans le processus PDR. On peut observer sur la figure que l'hypothèse retenue par le graphe est celle qui se rapproche le plus du cap PDR. Naturellement, plus le piéton avance et plus sa position filtrée s'éloigne de sa position réelle. Après avoir traversé la chaussée, le piéton descend par les escaliers et la détection d'un haut d'escaliers permet de rattraper cette erreur. Néanmoins, la recherche de POI a été fructueuse car l'erreur de positionnement du piéton au moment de la détection était en-dessous du rayon de recherche, ce qui démontre l'importance du graphe de navigation dans la gestion des erreurs d'orientation préalablement à la mise en place de la détection de POI.

Notons qu'il y a une différence supplémentaire entre ce cas et celui d'avant. En effet, les deux premiers POIs (bas d'escaliers, puis haut d'escaliers) sont consécutifs sans qu'une position filtrée soit entre les deux. Dans le deuxième cas, les deux POI (haut d'escaliers puis bas d'escaliers) sont reliés par une suite de positions filtrées. Rappelons que dans le premier cas il s'agit d'une montée d'escaliers et dans le second d'une descente. Cela signifie que la classe « Marche Normale » a été détectée trop tôt dans le premier cas, ce qui a donné lieu à la détection du haut d'escalier sans que l'algorithme n'ait eu le temps de calculer des positions intermédiaires. Cela s'explique notamment par les résultats de la classification qui ont montré que la probabilité de confusion entre les montées d'escaliers avec la marche normale était plus importante que celle de la confusion entre les descentes d'escaliers et la marche normale. Dans le cas de la 2ème détection, l'algorithme a reconnu la classe « descente d'escaliers » pendant une durée plus longue et plus proche de la réalité, ce qui a permis de calculer des positions intermédiaires en attendant que le piéton quitte la cage d'escaliers pour que la sortie du classifieur reconnue bascule vers « Marche Normale ».

VI.2.2.1.2.3 Erreur liée à la non-calibration du modèle de longueur de pas

Le troisième cercle blanc de la figure correspond à la correction d'erreur liée au modèle de longueur de pas. En effet, cette correction a lieu en indoor. Le graphe de navigation est donc bien adapté au mouvement piéton car la géométrie des couloirs est assez contraignante. L'erreur de distance provient ici d'un retard de propagation dû à la sous-estimation de la longueur de pas du piéton. C'est pour cette raison que dès qu'un coin de couloir est détecté, un saut en position a lieu pour atteindre le POI. S'il n'y avait pas eu de détection de coin de couloir et donc de mise à jour de position, les particules auraient été propagées suivant un segment du graphe parallèle au couloir réellement emprunté par le piéton.

VI.2.2.1.2.4 Transition IO

Le cercle jaune de la Figure 95 indique le POI correspondant à la porte d'accès au bâtiment. En effet, dans cette acquisition la transition IO n'est pas très difficile car elle est précédée d'une détection de bas d'escaliers et donc d'une première correction de distance. Cette mesure de position est venue compenser la dégradation du signal GNSS. Par ailleurs, il s'agit d'une entrée plus ou moins contrainte par des voies piétonnes, donc le graphe de navigation est plus fiable par rapport à d'autres cas de figures plus imprédictibles. Néanmoins, la détection de l'accès au bâtiment a bien eu lieu, ce qui montre qu'elle aurait pu corriger une erreur éventuellement plus importante selon le rayon de recherche toléré dans l'algorithme de détection.

La deuxième porte d'accès au bâtiment n'a pas été détectée, ce qui correspond à une omission. Cette erreur n'a pas une probabilité nulle selon les résultats de la classification. Cependant, son seul

impact reste une absence de correction et non pas une introduction d'erreur supplémentaire dans le processus de localisation.

VI.2.2.2 Scénario 2

VI.2.2.2.1 Trajectoire estimée

La Figure 96 montre trois trajectoires différentes. La trajectoire de référence est donnée en vert, la trajectoire PDR en cyan et la trajectoire estimée en rouge. La dérive est visible sur les deux extrémités Nord-Est et Sud-Ouest de la carte où la trajectoire cyan s'éloigne des trottoirs. Du point de vue de la forme simplement (morphologie), la trajectoire estimée correspond bien au trajet planifié (Figure 91).

La Figure 97 présente un zoom des phases avant et après l'entrée dans le bâtiment. Le graphe de navigation est sous forme d'un maillage régulier afin de modéliser une absence de contraintes géométriques. Les positions estimées dans cette zone forment une courbe, ce qui est plutôt réaliste car il n'y a plus de trottoir pour contraindre la géométrie de la trajectoire. Pendant la phase de transition IO, la figure montre une discontinuité qui traduit un changement de paramétrage au niveau du filtre particulière. En effet, le piéton arrive d'un milieu non masqué où positions GNSS et caps de marche agissent ensemble sur la trajectoire. Une fois qu'il se rapproche du bâtiment, le SNR montre une dégradation du signal GNSS qui n'est pas assez forte pour rejeter les positions. Cela signifie que le filtre continue de faire des mises à jour en fonction des positions GNSS bien qu'elles tendent à devenir imprécises. Or dans cette configuration il n'est pas possible d'agir autrement : les mesures de caps PDR sont inexploitable du fait que le graphe de navigation sous forme de maillage régulier ne le permette pas. Lorsqu'il n'y a plus de signal GNSS, les caps PDR sont à nouveau pris en compte et cela provoque un saut de position traduisant l'écart entre la dernière position calculée en outdoor et la première position calculée en indoor. Malgré ce saut, le filtre particulière a permis de rattraper les erreurs cumulées au cours de la transition IO et ce au moment où le piéton a changé de couloir. Les particules mal positionnées se retrouvant sur un couloir dont l'orientation est à environ 90° de la mesure PDR, elles ont été détruites par le filtre. Les particules se trouvant à la bonne distance (pas loin du coin de bâtiment) ont pu être propagées sur le bon couloir et survivre au processus de sélection. Ce résultat démontre l'avantage d'utiliser un filtre particulière. En effet, grâce à un nombre important de particule, au moins une particule a été propagée selon la bonne distance et a permis de calibrer la trajectoire.

VI.2.2.2.2 Calcul d'erreurs

La Figure 98 montre l'histogramme des erreurs planimétriques calculées par différence entre les coordonnées horodatées des positions de référence et les positions filtrées. Dans l'ensemble, une erreur moyenne de 3m est obtenue. Lorsque l'erreur est de 5-6 m, cela traduit souvent une absence d'hypothèse au sein du graphe de navigation, comme une traversée de route en dehors des passages piétons. C'est une erreur qui a l'ordre de grandeur de la largeur de la chaussée. En indoor, aucune trajectoire de référence n'est disponible. Les positions calculées en indoor peuvent être appréciées qualitativement par comparaison avec le plan d'intérieur. En effet, lorsque la position est au milieu du couloir, on peut distinguer l'erreur transversale (suivant la direction orthogonale au couloir) de l'erreur longitudinale (le long du couloir). La première est souvent inférieure à la demi-largeur du couloir. La seconde est plus difficile à déterminer car elle nécessite la disponibilité de points balisés et elle traduit l'exactitude de la distance. Néanmoins, les coins de bâtiments sont intrinsèquement des balises permettant de détruire les particules dont les paramètres de distance sont très loin de la réalité. Les positions filtrées correspondant aux coins de couloirs sont de ce fait très précises. Or si elles sont précises cela signifie que celles d'avant le sont aussi car sinon les particules n'atteindraient pas le coin au bon moment.

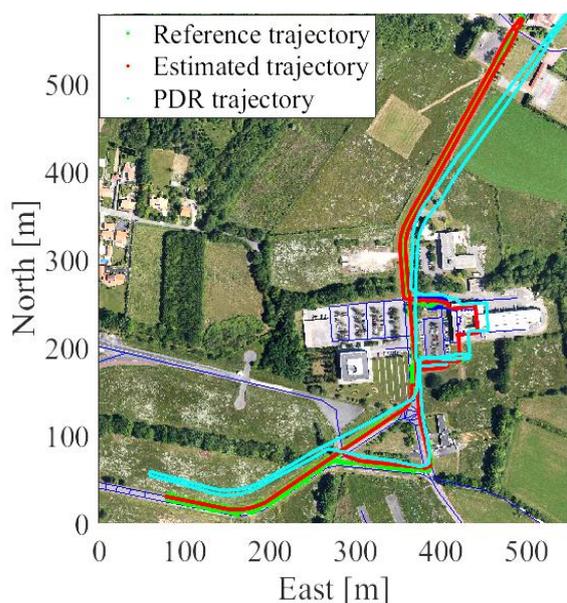


Figure 96 : La trajectoire de référence est donnée en vert, la trajectoire estimée par filtrage est en rouge et la trajectoire obtenue par le modèle PDR en cyan.

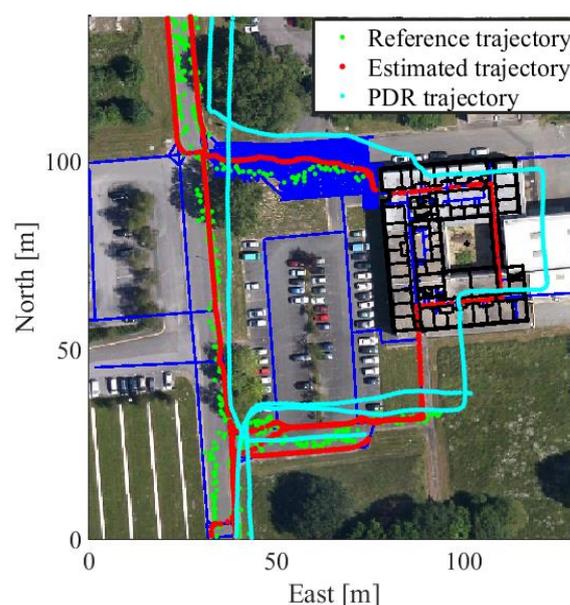


Figure 97 : Zoom sur la partie indoor

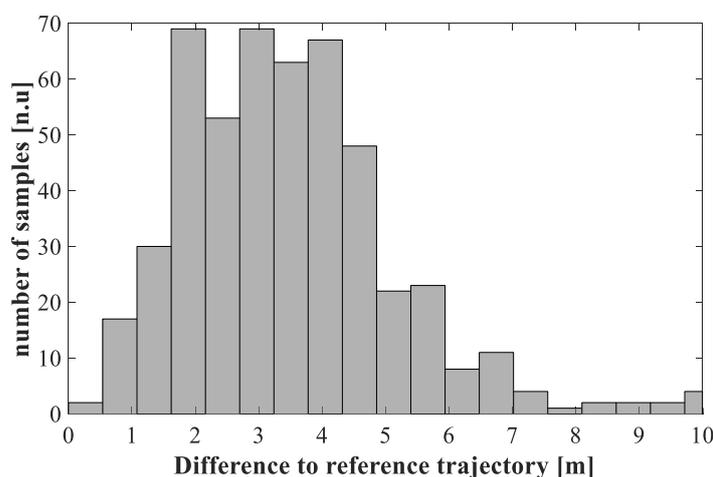


Figure 98 : Histogramme des erreurs calculées par comparaison des positions de référence avec les positions filtrées

VI.2.2.2.3 Calibration du facteur d'échelle

La Figure 99 décrit le comportement du facteur d'échelle pendant les différentes phases du déplacement du piéton. Il est observé que les phases de marche en ligne droite (comprises entre les lignes magenta) sont les mieux adaptées pour calibrer le facteur d'échelle. Sa moyenne est donnée par la ligne rouge sur le graphique, correspondant à une valeur de 0,93. Rappelons que cette valeur est estimée une fois pour toutes car elle ne dépend que de la physiologie du piéton et est indépendante du temps.

Le facteur d'échelle dérive en dehors de ces phases. C'est le cas par exemple lorsque le piéton fait demi-tour (entre les lignes cyan). Il atteint deux extrema locaux avant d'être remis à sa valeur moyenne une fois qu'une ligne droite est suivie à nouveau par le piéton. Les lignes vertes marquent la phase pendant laquelle les particules traversent le maillage et où le facteur d'échelle diverge en raison des différentes difficultés expliquées dans le paragraphe précédent. En entrant dans le bâtiment (entre les lignes jaunes), le facteur d'échelle dérive également, et ce pour les mêmes raisons accentuées qu'avant d'être entré dans le bâtiment. Enfin, les lignes grises indiquent la phase pendant laquelle le piéton quitte le bâtiment. Les mêmes difficultés sont observées qu'au moment de l'entrée. Ces résultats démontrent qu'il faut profiter de la disponibilité du GNSS pendant des trajets droits pour calibrer le facteur d'échelle et le stocker pour une réutilisation en intérieur.

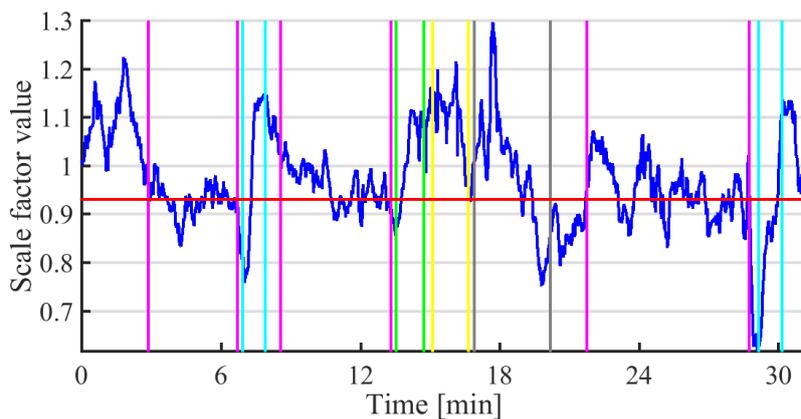


Figure 99 : Facteur d'échelle correctif du modèle de longueur de pas affiché en fonction du temps

VI.2.2.2.4 Correction angulaire

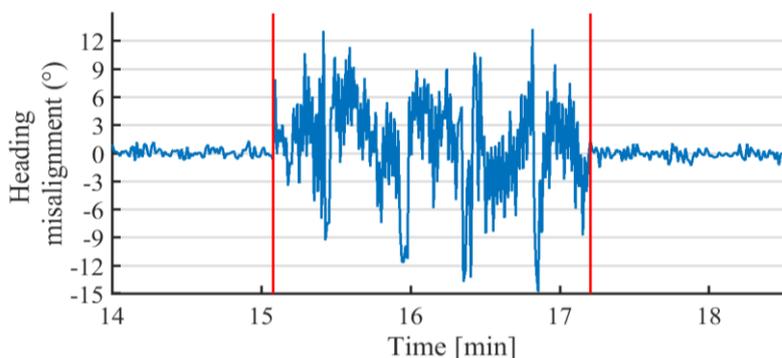


Figure 100 : Valeurs correctives du biais angulaire entre l'orientation de ULISS et le cap de marche (orientation des couloirs)

La Figure 100 montre le défaut d'alignement estimé entre l'orientation du capteur ULISS et le cap de marche suivi par le piéton pendant le trajet indoor. Cette phase est délimitée par les lignes rouges sur le graphique. Cette correction n'est pas réalisée en extérieur car les incertitudes sur le graphe sont plus importantes qu'en intérieur. Cette limite sera ultérieurement corrigée (VI.2.2.3) pour que les calibrations aient lieu en intérieur mais aussi en extérieur. Globalement, le défaut d'alignement reste inférieur à une valeur absolue de 15° , ce qui est sensé car l'acquisition est réalisée dans un mode Texting. La plupart des valeurs sont comprises entre -5° et $+5^\circ$ avec de faibles oscillations dues à la cyclicité du processus de marche. Les valeurs extrémales indiquent les coins de couloirs (Il y en a 4 au total). En effet, même si le piéton suit un parcours contraint par la géométrie des couloirs, autour des coins de bâtiments, il tourne de manière progressive en introduisant de brèves phases ambiguës où un grand nombre de particules sont sélectionnées de part et d'autre d'un coin. A ce moment-là l'erreur angulaire croît car elle dépend de plusieurs facteurs dont l'ambiguïté due au changement de direction, le défaut d'alignement, etc. Il faut alors attendre que le piéton soit engagé sur le nouveau couloir pour que cette erreur baisse à nouveau.

VI.2.2.3 Scénario 3

VI.2.2.3.1 Trajectoires estimées

La Figure 101, la Figure 102 et la Figure 103 montrent les trajectoires estimées (en rouge) avec le graphe de navigation généré par l'algorithme A*. Le trajet cyan correspond à la trajectoire PDR, tandis que le vert correspond à la trajectoire de référence obtenue par GNSS différentiel.

La Figure 101 et la Figure 102 correspondent aux acquisitions effectuées en mode Texting. Les deux participants ont réalisé une boucle fermée autour du bâtiment, avec un parcours intermédiaire en extérieur (partie Sud des figures).

Pour les deux premières acquisitions, la distance parcourue est visiblement surestimée car les trajets cyan sont plus longs que le trajet réalisé. La détermination du cap est quant à elle plus correcte pour la première acquisition car la forme de la trajectoire est plus fidèle à l'architecture du bâtiment. La dérive est également plus importante pour le deuxième jeu de données d'après la Figure 102. En effet, lorsque la dérive est trop importante, la trajectoire PDR présente des incohérences majeures vis-à-vis de la carte : Les trajets ne font pas de sens par rapports aux différentes voies piétonnes. D'après les deux figures, d'un point de vue purement qualitatif, la dérive a été corrigée par le filtre particulière car les trajectoires estimées sont plus conformes avec la structure du bâtiment et avec les différentes voies piétonnes en extérieur. Cette conformité indique également que la distance a été corrigée par exploitation du graphe de navigation.

La Figure 103 correspond au troisième trajet qui comprend une phase en Texting et une phase en Swinging. Visuellement, on peut observer que la longueur de pas est sous-estimée pendant l'aller et surestimée au retour. Cela signifie que le mode Swinging agit sur l'estimation des longueurs de pas qui est elle-même liée à l'estimation de la fréquence de marche. La phase Swinging sous-tend également des caps moins précis. Ces différentes observations ont été prises en compte par le

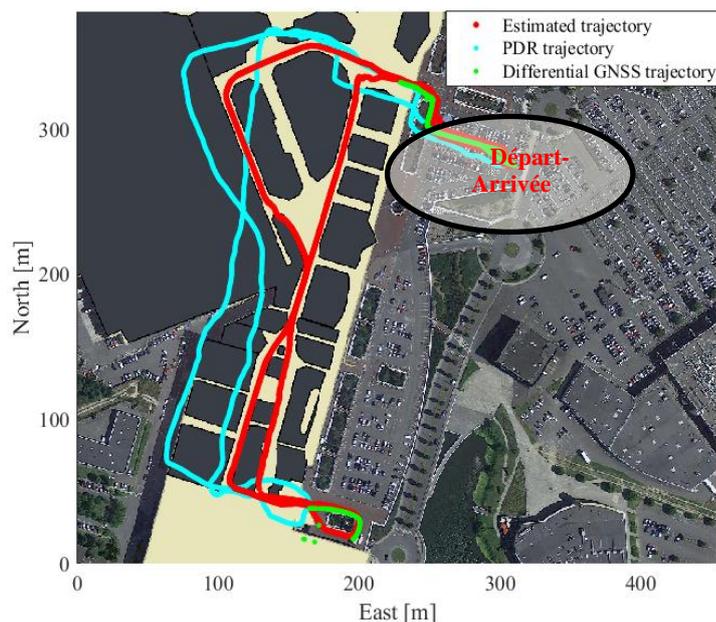


Figure 101 : Trajectoire estimée pour le premier scénario (Texting)

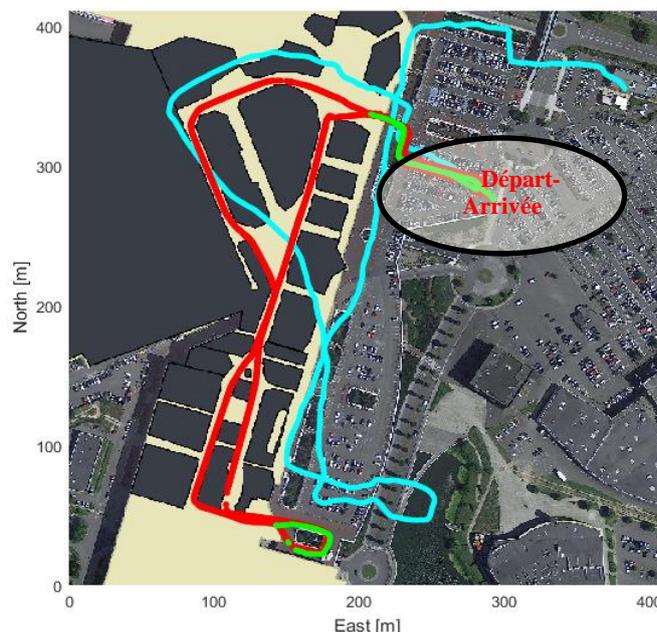


Figure 102 : Trajectoire estimée pour le second scénario (Texting)

filtre et cela est visible au niveau de la trajectoire rouge. Elle est plus conforme avec le trajet réalisé ainsi qu'avec la carte. Cette figure montre néanmoins une erreur d'appariement avec la carte au moment de la première sortie du piéton de l'intérieur vers l'extérieur (Partie Nord de la carte). La trajectoire estimée montre en effet que le piéton allait s'engager dans un couloir (Celui de droite). Cette hypothèse n'a été abandonnée qu'après un certain temps et cela est traité dans la partie VI.2.2.3.4.

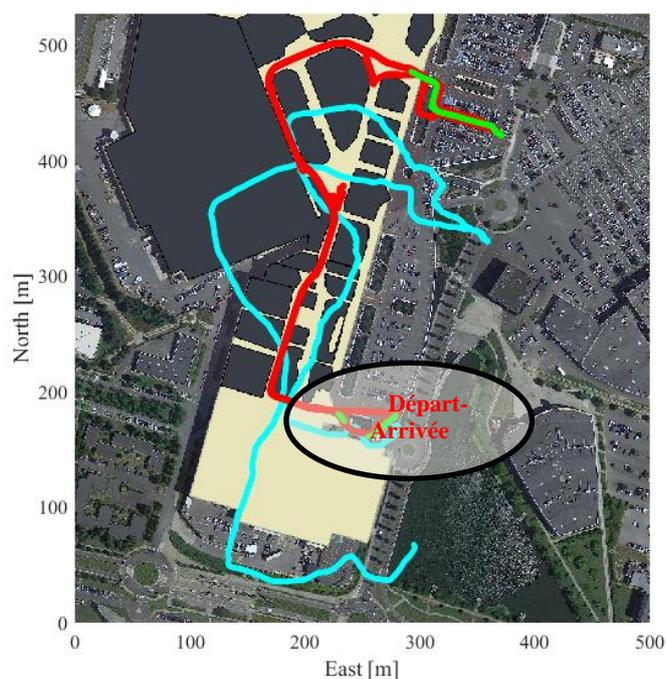


Figure 103 : Trajectoire estimée pour le troisième scénario (Texting, Swinging)

VI.2.2.3.2 Calcul d'erreurs

Les positions filtrées ont été comparées aux positions de référence interpolées à la fréquence de pas. L'erreur planimétrique moyenne varie de 4 à 5 mètres pour les trois ensembles de données (Figure 104). Les précisions obtenues augmentent avec la qualité des trajectoires PDR. Il est donc normal que les erreurs calculées soient plus importantes pour la troisième acquisition qui comprend une phase Swinging. Les outliers (croix rouges) sont également plus nombreux et avec des erreurs beaucoup plus importantes pour le troisième trajet. Ces erreurs sont principalement dues à des paramètres PDR non calibrés et sont abordées dans les paragraphes suivants.

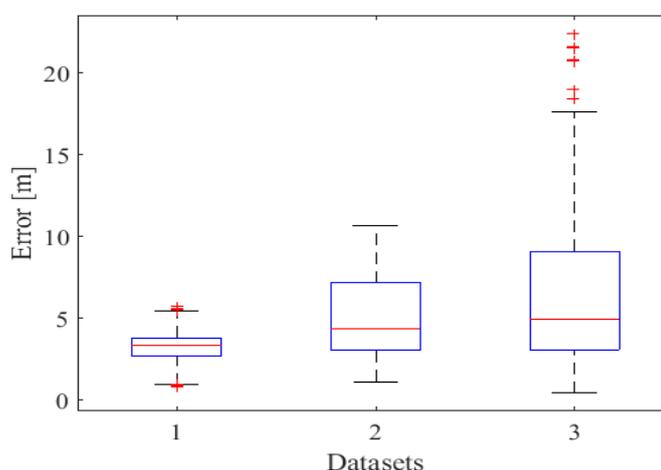


Figure 104 : Distribution de l'erreur planimétrique pour chaque acquisition

VI.2.2.3.3 Correction du défaut d'alignement angulaire

Les figures ci-dessous montrent les valeurs du défaut d'alignement angulaire estimé pour chaque acquisition. Pour le premier trajet (Figure 105), le défaut d'alignement angulaire est compris entre -10° et $+10^\circ$ et varie autour d'une valeur moyenne approximative de 0° . Selon cette répartition, la différence angulaire entre les directions de marche et la direction du capteur est minime, ce qui est le cas dans un scénario Texting.

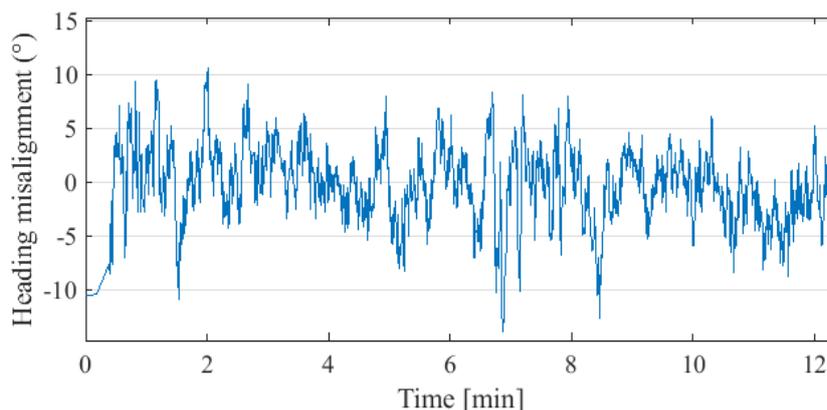


Figure 105 : Défaut d'alignement angulaire estimé pour le premier trajet

La Figure 106 correspond au deuxième trajet. Les valeurs estimées du défaut d'alignement angulaire sont comprises entre -15° et $+12^\circ$. Elles ne sont par ailleurs pas réparties de manière équitable autour de 0° (par exemple, entre la 1ère et la 2ème minute, la valeur moyenne est aux alentours de 2°). À partir de cette analyse, on peut supposer que le piéton n'a pas réellement dirigé le capteur dans le même sens que le cap de marche, bien que l'acquisition ait été réalisée avec cette intention.

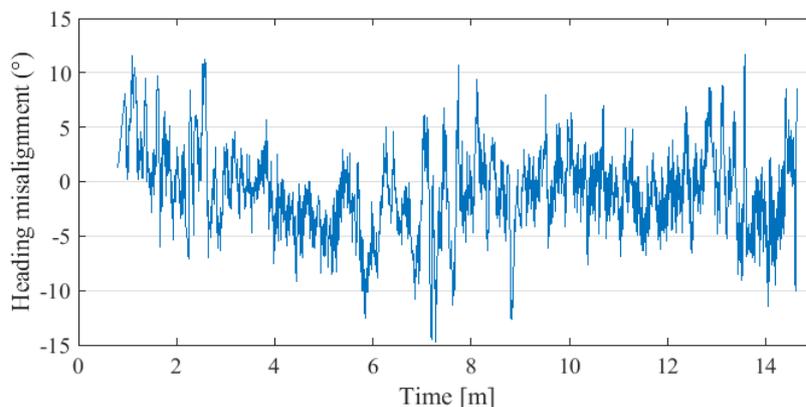


Figure 106 : Défaut d'alignement angulaire estimé pour le deuxième trajet

La Figure 107 fournit la même statistique pour le troisième trajet. La première partie (jusqu'à environ la 10^{ème} min) a été effectuée en mode Swinging. Par conséquent, les valeurs estimées varient considérablement (-15° à $+20^\circ$) avec des fluctuations plus fréquentes et plus amples. Notons que la majeure part du mouvement Swinging se fait selon l'axe Est du repère de navigation, ce qui devrait davantage se répercuter sur l'angle de tangage. Le filtre n'estime que la part d'erreur impactant le lacet qui se traduit par une erreur d'azimut sur le cap de marche. Pour la deuxième partie du trajet, des oscillations entre $\pm 5^\circ$ autour d'une valeur moyenne de 0° sont retrouvées, reflétant le mode Texting de la fin de l'acquisition.

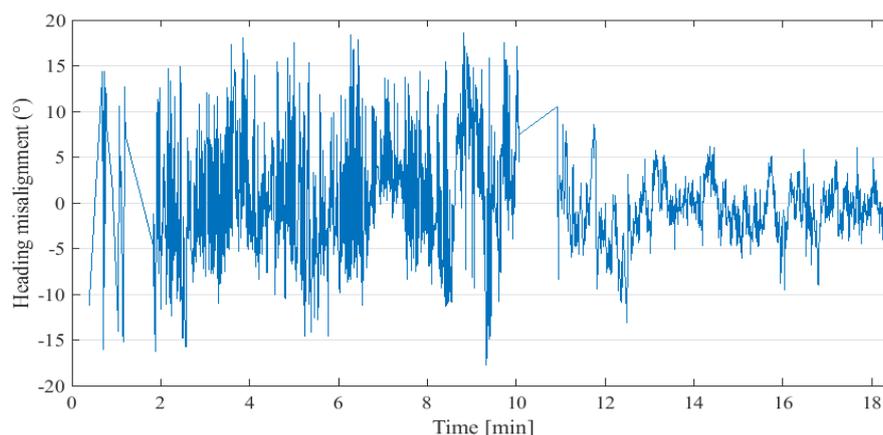


Figure 107 : Défaut d'alignement angulaire estimé pour le troisième trajet

VI.2.2.3.4 Estimation du facteur d'échelle

Un facteur d'échelle a été introduit dans le modèle de longueur de pas afin de l'ajuster au piéton. Cependant, en raison des courtes périodes de marche en extérieur, le facteur d'échelle n'a pas pu être calibré car il nécessite la disponibilité du GNSS comme expliqué en VI.2.2.2.3. Par conséquent, seules les valeurs de caps ont été prises en compte dans le processus de sélection des particules. Les seules corrections de distance possibles dans ce cas ont lieu aux nœuds du graphe qui représentent des changements de direction majeurs (ex. changement de couloirs). Cela explique notamment la correction de distance visible sur les trajectoires obtenues. Ce manque de calibration a toutefois des répercussions sur le processus d'appariement avec la carte. Ces répercussions sont principalement des retards au niveau de la détection du changement d'orientation dans le cas d'une sous-estimation de la longueur de pas, ou des avances dans le cas d'une surestimation de la longueur de pas. A titre d'exemple la Figure 103 montre un retard au niveau de la sortie Nord du bâtiment. En effet, alors que le piéton avait l'intention de sortir du bâtiment, la trajectoire filtrée indique qu'il se dirigeait vers un couloir. Cela s'est produit pour deux raisons. Tout d'abord, la trajectoire réelle est assez inhabituelle en termes de comportement piéton. En fait, il y a un changement de cap (observé dans la trajectoire PDR) qui est indépendant de la configuration géométrique de l'espace. Cela invalide notamment les aprioris qui ont permis de construire notre réseau de navigation. Deuxièmement, la distance de marche non calibrée empêchait les particules d'atteindre l'espace extérieur au bon moment. Une autre erreur d'appariement avec la carte s'est produite au milieu du bâtiment (entre 300 m et 400 m selon la direction du Nord) parce que le changement de direction a été détecté trop tard en raison d'une distance de marche non calibrée. Par la suite, le filtre a corrigé cette erreur et a convergé vers la bonne hypothèse.

VI.3 Conclusions

Nous avons analysé les résultats de trois scénarios qui adressent trois problématiques différentes. D'après ces résultats nos contributions peuvent être résumées selon les points suivants :

- 1- La correction de la dérive suppose un effet mémoire dans le processus de localisation. Cela est différent du biais angulaire lié à l'orientation du capteur par rapport au cap de marche. Cet effet se représente sous forme d'un écart-type de marche aléatoire pris en compte dans le modèle de sélection des particules.
- 2- Le biais angulaire (défaut d'alignement) est corrigé grâce à l'information de cap donné par le graphe de navigation et ce à tout instant. Cela ne suppose aucun effet mémoire et peut donc être réalisé à n'importe quel moment du trajet pourvu que les hypothèses du graphe soient réalistes.
- 3- Le GNSS pendant les trajets en ligne droite permet de calibrer le facteur d'échelle qui corrige le modèle de longueur de pas. Bien que ce modèle soit ajusté, des erreurs de distance peuvent être introduites à cause de la qualité du graphe. Nous avons notamment traité cette problématique dans le deuxième scénario qui a proposé une architecture de graphe servant dans les zones non contraintes par des obstacles et où la pertinence du graphe est forcément

- discutable.
- 4- D'après les trois points précédents, la dérive est prise en compte, le biais angulaire est estimé grâce au graphe, et le modèle de longueur est ajusté en outdoor puis fixé en indoor. Les erreurs restantes sont principalement des erreurs de distance liées à la qualité du graphe de navigation et à la correction de la dérive angulaire. En effet, si l'erreur d'attitude est plus importante que celle prévue dans l'écart-type modélisant le comportement de marche aléatoire (ex. à cause d'une perturbation du champ magnétique), le modèle prévu pour la correction angulaire devient insuffisant. La détection de POI sert dans ces situations à rattraper l'erreur de distance tant que l'erreur n'est pas trop importante. Cela signifie que la base de données des POI à détecter doit être assez riche pour que la détection ait lieu avant que l'erreur ne soit supérieure au rayon de recherche prévu dans le cadre de la détection. Ce dernier point était l'objet de la première acquisition réalisée sur un court trajet.

Conclusion et perspectives

VII. Conclusion générale

Cette thèse s'est intéressée à l'amélioration de la localisation du piéton par fusion des capteurs de navigation d'un smartphone, y compris le GNSS, et à l'aide de la carte. Le rôle de la carte consiste principalement à rendre compte du comportement piéton, notamment en matière de représentation de l'espace navigable tenant compte du profil de mobilité de l'utilisateur. La qualité des capteurs utilisés et les conditions de navigation piétonne, celle-ci se déroulant souvent en espace urbain ou en intérieur, rendent une localisation précise plus difficile qu'en extérieur. D'une part le signal GNSS est dégradé voire indisponible en présence de masques, et d'autre part les méthodes de navigation inertielle sont limitées par une accumulation d'erreurs au fur et à mesure du déplacement. Les recherches menées dans cette thèse sont concentrées autour de l'exploitation de la carte pour dépasser ces difficultés. Dans une optique PDR (pedestrian dead reckoning) avec un capteur porté en main, nous avons deux axes d'amélioration à investiguer. Le premier est la correction de la composante angulaire de l'erreur globale, et le second est la correction de sa composante de distance. La composante angulaire se divise en deux sous-composantes qui sont un biais dû au défaut d'alignement entre le capteur en main et la direction de marche, et le second est une dérive résultant du calcul d'attitude du capteur. La composante de distance est également issue principalement de deux sous-composantes correspondant à une erreur de détection de pas et à une erreur d'estimation de la longueur de pas.

En ce qui concerne les erreurs angulaires, l'état de l'art montre qu'on s'est généralement intéressé à corriger à la fois le biais et la dérive de manière indissociée. La correction se fait usuellement grâce à l'information géométrique de la carte en fixant un seuil de tolérance sur l'écart angulaire entre l'attitude du capteur et l'orientation du couloir/trottoir. Des modèles statistiques ont également été proposés pour prédire la direction de marche à partir du signal du capteur tenu en main, ce qui est une manière d'isoler le biais. Quant à la composante de distance, les erreurs de détection ne sont pas spécifiquement traitées dans la littérature. Pour les erreurs d'estimation de longueur de pas, elles sont généralement traitées par reconnaissance sur le signal. Il s'agit souvent d'adapter la longueur de pas à la vitesse de marche, ou le modèle de distance au contexte spatial, par exemple dans le cas des cages d'escaliers, la longueur de pas est remplacée par la largeur de la marche. La non-distinction des erreurs de détection et des erreurs liées au modèle de longueur de pas nous a semblé être une insuffisance majeure dans les méthodes existantes. En effet, une erreur de longueur de pas est de l'ordre du centimètre, tandis qu'une erreur de détection est de l'ordre du mètre. Il est donc clair que les erreurs de détection de pas, bien qu'elles ne soient pas systématiques, ont un impact individuel plus important que les imprécisions des modèles de longueurs de pas.

Après revue de ces limites, plusieurs pistes de corrections ont été étudiées et ont dirigé les travaux de cette thèse. Un filtre particulière a été conçu de manière à modéliser l'erreur de dérive et le biais angulaire de manière distincte. Cette correction est constamment réalisée grâce aux mesures de direction de marche fournies par un graphe de navigation. Les phases opportunes durant lesquelles des positions GNSS précises et régulières sont disponibles sont exploitées pour calibrer le modèle de longueur de pas. Une fois réalisée, cette calibration reste valable aussi en indoor car elle intègre un systématisme de marche propre à l'utilisateur et indépendant du temps. Le même principe a été adopté pour intégrer au filtre une variable aléatoire qui permet de détecter les faux pas (pas sur/sous détectés). Enfin, l'absence de GNSS dans les milieux masqués a été palliée par un processus de détection de points d'intérêt couvrant l'indoor et l'outdoor. Il s'agit d'une augmentation du filtre particulière permettant de réinitialiser la position du piéton afin de rattraper les erreurs que le filtre n'a pas pu corriger dans les situations critiques. La situation la plus critique dans ce travail est le concours d'une indisponibilité de position GNSS avec une sélection d'hypothèse fautive dans le graphe de navigation, soit parce que ce dernier ne contient pas l'hypothèse vraie, soit parce que le filtre n'a pas eu le temps de converger vers elle.

Avec ce modèle de fusion, trois volets d'améliorations ont émergé. D'abord, il s'est avéré que la

transition indoor-outdoor ou inversement exigeait un traitement particulier afin d'assurer la continuité de la solution entre l'indoor et l'outdoor. Plus sa détection est rapide, plus l'accumulation d'erreurs dues à la perte de GNSS et aux imprécisions du graphe est limitée. Par ailleurs, la continuité de la solution requiert aussi de proposer un modèle de graphe qui puisse assurer les calibrations PDR dans les zones non-contraintes par les obstacles. Peu de recherches ont été menées sur les architectures de graphe optimales dans les espaces ouverts dans un objectif de calibration de modèles PDR. Nous avons constaté dans la littérature que les champs de recherches sur la modélisation des graphes et sur la modélisation des erreurs PDR sont traités de manière indépendante. L'étude conjointe de l'une et l'autre et des relations possibles entre elles nous a semblé importante. Enfin, pour l'augmentation du filtre avec une détection de POIs (points d'intérêt), il a été constaté que la détection de la transition IO avec les capteurs de navigation usuels est très peu documentée, et que la plupart des méthodes existantes avec des capteurs et des modes de détection divers s'intéressent très peu à la généralisation des algorithmes de reconnaissance à des environnements nouveaux.

Trois solutions ont été suggérées dans ce travail pour combler ces lacunes. D'abord, la détection de la transition IO avec les capteurs de navigation usuels a été investiguée. Etant donné le manque d'information sur les descripteurs pertinents vis-à-vis de la détection IO, trois méthodes de sélection ont été adoptées et ont été comparées après application de trois algorithmes de reconnaissance différents. Cette recherche a été fructueuse car les résultats ont montré que la détection IO était faisable avec des capteurs inertiels, un baromètre et un magnétomètre. Ensuite, une architecture de graphe permettant des calibrations en zones ouvertes a été proposée et a été mise en œuvre sur des données expérimentales. Elle a notamment assuré la continuité de la localisation du piéton malgré le passage par une zone de transition IO qui est suivie d'une zone non contrainte par les obstacles. Enfin, les données recueillies pour la reconnaissance sur le signal et la détection de POI ont été scindées en données d'apprentissage et données de validation. Ces dernières sont issues d'environnements (bâtiments et personnes) qui n'ont pas participé au processus d'apprentissage. Cela a montré qu'une sélection pertinente des descripteurs combinée à un modèle d'apprentissage approuvé dans la littérature permet de conserver un certain niveau de performances y compris lorsque ces descripteurs et ce modèle sont déployés dans des environnements nouveaux.

VIII. Perspectives

Les différentes améliorations proposées dans ce travail démontrent l'apport de la carte en termes d'aide à la localisation du piéton, notamment dans les milieux masqués où le GNSS est remplacé par les approches de navigation inertielle. Une des grandes difficultés a consisté à extraire de la carte l'information utile à la fois pour modéliser l'espace navigable par le piéton, mais aussi pour restreindre au maximum l'espace de recherche de sa position. En effet, les aléas de la navigation piétonne sont trop nombreux en comparaison avec les véhicules à cause d'une liberté de mouvement plus importante, d'une grande variabilité des profils de mobilité - information dont il faut tenir compte pour la planification d'itinéraire - et finalement du libre arbitre de l'utilisateur qui peut décider à tout moment de changer de destination ou tout simplement de ne pas suivre le chemin optimal. Dans ce contexte, nous avons montré que les réseaux de navigation présentés sous forme de graphes topologiques apportent souvent des aprioris permettant une localisation plus précise. Cependant, ces mêmes réseaux contiennent parfois de fausses hypothèses engendrant des erreurs qui ne peuvent être détectées instantanément et qui s'accumulent au fil du temps. Dans le cadre de la navigation des PMR, ce cas de figure ne devrait pas se produire. Aussi, l'approche proposée dans ce travail n'est efficace dans le cas des PMR qu'à condition qu'une planification d'itinéraire soit réellement mise en œuvre avec une personnalisation tenant compte du handicap de l'utilisateur, mais aussi à condition que ce dernier se limite au nombre d'itinéraires proposés afin de bénéficier efficacement des informations de la carte. Si ces deux conditions sont remplies, la carte apporterait plus de sécurité à l'utilisateur et permettrait une localisation plus précise tout en considérant le libre arbitre de l'utilisateur grâce à une approche multi-hypothèses, ce qui revient par définition à résoudre un problème multimodal, d'où l'intérêt d'une approximation particulière.

Références

- [1] P. D. Groves, "Principles of GNSS, Inertial, and Multisensor Integrated Navigation Systems", 2nd ed. Artech house, Chap. 4: Inertial Sensors, 2013.
- [2] "PNI offers dead reckoning processor | EETE Analog." [Online]. Available: <http://www.eenewsanalog.com/news/pni-offers-dead-reckoning-processor>. [Accessed: 01-Oct-2018].
- [3] A. Norrdine, Z. Kasmi, and J. Blankenbach, "Step Detection for ZUPT-Aided Inertial Pedestrian Navigation System Using Foot-Mounted Permanent Magnet," *IEEE Sens. J.*, vol. 16, no. 17, pp. 6766–6773, 2016.
- [4] F. Chollet and H. Liu, "A (not so) short introduction to Micro Electro Mechanical Systems," version 5.1, 2013.
- [5] M. Andrejašič, "Mems accelerometers," in University of Ljubljana. Faculty for mathematics and physics, Department of physics, Seminar, March 2008.
- [6] P. D. Groves, "Principles of GNSS, Inertial, and Multisensor Integrated Navigation Systems, 2nd ed. Artech house, Chap. 2: Earth Surface and Gravity Models, 2013.
- [7] B. VELAY, "Modélisation d'un accéléromètre MEMS.", Département Mesures physiques, Institut universitaire de technologie (IUT) de Saint Nazaire. January 2010.
- [8] V. Apostolyuk, "Theory and design of micromechanical vibratory gyroscopes," in *MEMS/NEMS*, Springer, pp. 173–195, 2006.
- [9] A. A. Trusov, "Overview of MEMS Gyroscopes: History, Principles of Operations, Types of Measurements," Whitepaper, UC Irvine, 2011.
- [10] V. Renaudin, M. H. Afzal, and G. Lachapelle, "New Method for Magnetometers Based Orientation Estimation," *IEEE/ION Position, Location and Navigation Symposium*, Indian Wells, CA, 2010, pp. 348-356.
- [11] S. Chable and V. Renaudin, "Couplage de mesures GPS et inertielles pour de la navigation pédestre dans les bâtiments," *XYZ*, vol. 146, pp. 27–32, 2016.
- [12] X. Zhang, Y. Li, P. Mumford, and C. Rizos, "Allan Variance Analysis on Error Characters of MEMS Inertial Sensors for an FPGA-based GPS / INS System," *Int. Symp. GPS/GNSS*, pp. 127–133, 2008.
- [13] P. D. Groves, "Principles of GNSS, Inertial, and Multisensor Integrated Navigation Systems," 2nd ed. Artech house, Chap. 6: Dead Reckoning, Attitude, and Height Measurement, 2013.
- [14] V. Renaudin and C. Combettes, "Magnetic, acceleration fields and gyroscope quaternion (MAGYQ)-based attitude estimation with smartphone sensors for indoor pedestrian navigation," *Sensors (Switzerland)*, vol. 14, no. 12, pp. 22864–22890, 2014.
- [15] J. W. Kim, H. J. Jang, D.-H. Hwang, and C. Park, "A step, stride and heading determination for the pedestrian navigation system," *Journal of Global Positioning systems*, vol. 3 (1-2), pp.273-279, 2004.
- [16] A. R. Pratama, R. Hidayat, and others, "Smartphone-based pedestrian dead reckoning as an indoor positioning system," 2012 International Conference on System Engineering and Technology (ICSET), Bandung, 2012, pp. 1-6.
- [17] A. Brajdic and R. Harle, "Walk detection and step counting on unconstrained smartphones," In *Proceedings of the 2013 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, Zurich, Switzerland, 8–12 September 2013; pp. 225–234.
- [18] M. Susi, V. Renaudin, and G. Lachapelle, "Motion mode recognition and step detection algorithms for mobile phone users," *Sensors (Switzerland)*, vol. 13, no. 2, pp. 1539–1562, 2013.
- [19] K.-C. Lan and W.-Y. Shih, "Using Simple Harmonic Motion to Estimate Walking Distance for Waist-mounted PDR," 2012 IEEE Wireless Communications and Networking Conference (WCNC), Shanghai, 2012, pp. 2445-2450.

- [20] H. Wang, H. Lenz, A. Szabo, J. Bamberger, and U. D. Hanebeck, "WLAN-Based Pedestrian Tracking Using Particle Filters and Low-Cost MEMS Sensors," 2007 4th Workshop on Positioning, Navigation and Communication, Hannover, 2007, pp. 1-7.
- [21] I. Bylemans, M. Weyn, and M. Klepal, "Mobile Phone-Based Displacement Estimation for Opportunistic Localisation Systems," 2009 Third International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies, Sliema, 2009, pp. 113-118.
- [22] V. Renaudin, M. Susi, and G. Lachapelle, "Step Length Estimation Using Handheld Inertial Sensors," *Sensors*, vol. 12, no. 7, 2012, pp. 8507–8525.
- [23] W. Zijlstra, "Assessment of spatio-temporal parameters during unconstrained walking," *European Journal of Applied Physiology*, vol. 92, no. 1, 2004, pp. 39–44.
- [24] D. Alvarez, R. C. González, A. López, and J. C. Alvarez, "Comparison of step length estimators from wearable accelerometer devices," 2006 International Conference of the IEEE Engineering in Medicine and Biology Society, New York, NY, 2006, pp. 5964-5967.
- [25] J. Rose and J. G. Gamble, "Human Walking," Lippincott Williams & Wilkins, 2006, pp. 1-75.
- [26] S. H. Shin, C. G. Park, J. W. Kim, H. S. Hong, and J. M. Lee, "Adaptive Step Length Estimation Algorithm Using Low-Cost MEMS Inertial Sensors," 2007 IEEE Sensors Applications Symposium, San Diego, CA, 2007, pp. 1-5.
- [27] V. Renaudin, V. Demeule, and M. Ortiz, "Adaptative pedestrian displacement estimation with a smartphone," International Conference on Indoor Positioning and Indoor Navigation, Montbeliard-Belfort, 2013, pp. 1-9.
- [28] V. Renaudin, C. Combettes, and F. Peyret, "Quaternion Based Heading Estimation with Handheld MEMS in Indoor Environments," 2014 IEEE/ION Position, Location and Navigation Symposium - PLANS 2014, Monterey, CA, 2014, pp. 645-656.
- [29] S. Durand and F. Peyret, "Localisation précise en temps réel par mesures de phases des signaux GNSS," Laboratoire Central des Ponts et Chaussées, 2004, p. 103.
- [30] S. Durand and F. Peyret, "Localisation précise en temps réel par mesures de phases des signaux GNSS," Laboratoire Central des Ponts et Chaussées, 2004, pp. 21-26.
- [31] L. Morel and S. Durand, "Cours de géodésie," Ecole Supérieure des Géomètres et Topographes, Chap. 8 : GNSS, 2013.
- [32] S. Bandi and D. Thalmann, "Path finding for human motion in virtual environments," *Computational Geometry*, vol. 15, February 2000, pp. 103-127.
- [33] N. Victor, "Evaluation des déplacements piétons quotidiens : Application à la ville de Luxembourg," Université de Lyon, 2016.
- [34] S. Kammoun, F. Dramas, B. Oriolaand, and C. Jouffrais, "Route selection algorithm for Blind pedestrian," ICCAS 2010, Gyeonggi-do, 2010, pp. 2223-2228.
- [35] A. Helal, S. E. Moore, and B. Ramachandran, "Drishti: an integrated navigation system for visually impaired and disabled," Proceedings Fifth International Symposium on Wearable Computers, Zurich, Switzerland, 2001, pp. 149-156.
- [36] T. S. T. Yusof, S. F. Toha, and H. M. Yusof, "Path Planning for Visually Impaired People in an Unfamiliar Environment Using Particle Swarm Optimization," *Procedia Computer Science*, vol. 76, 2015, pp. 80–86.
- [37] S. Izumi, G. Kobayashi, and T. Yoshida, "Route navigation method for disabled access GIS in consideration of abilities and psychologies," 2007 2nd International Conference on Digital Information Management, Lyon, 2007, pp. 519-525.
- [38] R. W. Saaty, "The analytic hierarchy process—what it is and how it is used," *Mathematical Modelling*, vol. 9, 1987, pp. 161–176.
- [39] J. Balata, Z. Mikovec, P. Bures, and E. Mulickova, "Automatically generated landmark-enhanced navigation instructions for blind pedestrians," in 2016 Federated Conference on Computer Science and Information Systems (FedCSIS), 2016, pp. 1605–1612.
- [40] R. G. Golledge, J. R. Marston, J. M. Loomis, and R. L. Klatzky, "Stated Preferences for Components of a Personal Guidance System for Nonvisual Navigation," *Journal of visual*

- impairment and blindness, vol. 98, March 2004, pp. 135–147.
- [41] H. Holone, G. Misund and H. Holmstedt, "Users Are Doing It for Themselves: Pedestrian Navigation with User Generated Content," The 2007 International Conference on Next Generation Mobile Applications, Services and Technologies (NGMAST 2007), Cardiff, 2007, pp. 91-99.
- [42] J.-F. Girres, "Modèle d'estimation de l'imprécision des mesures géométriques de données géographiques," Paris Est, 2012.
- [43] "Géoportail," [Online]. Available: <https://www.geoportail.gouv.fr>. [Accessed: 1st-Jan-2019].
- [44] "QGIS," [Online]. Available: <https://www.qgis.org/fr/site/>. [Accessed: 12-Jan-2019].
- [45] "Map Features — OpenStreetMap Wiki," [Online]. Available: https://wiki.openstreetmap.org/wiki/Map_Features. [Accessed: 12-Jan-2019].
- [46] J.-F. Girres and G. Touya, "Quality Assessment of the French OpenStreetMap Dataset," Transactions in GIS, vol. 14, no. 4, 2010, pp. 435–459.
- [47] "Sidewalks — OpenStreetMap Wiki," [Online]. Available: <https://wiki.openstreetmap.org/wiki/Sidewalks>. [Accessed: 12-Jan-2019].
- [48] O. Petit, P. Billon, and J.-M. Follin, "Évaluation de la qualité des données OpenStreetMap sur la Sarthe et réflexion sur le processus de contribution," XYZ, vol. 2, no. 131, 2012, pp. 37–47.
- [49] "AutoCAD pour Mac et AutoCAD pour Windows Logiciel de CAO Autodesk." [Online]. Available: <https://www.autodesk.fr/products/autocad/overview>. [Accessed: 12-Jan-2019].
- [50] "OSM goes indoors: usages, tools and prospects." [Online]. Available: <https://fr.slideshare.net/cartocite/osm-goes-indoors-usages-tools-and-prospects>. [Accessed: 28-Feb-2018].
- [51] "Google Maps Platform | Tarifs et forfaits." [Online]. Available: <https://enterprise.google.fr/intl/fr/maps/pricing/>. [Accessed: 12-Jan-2019].
- [52] C. S. Jensen, H. Lu, and B. Yang, "Graph Model Based Indoor Tracking," in 2009 Tenth International Conference on Mobile Data Management: Systems, Services and Middleware, 2009, pp. 122–131.
- [53] I. Afyouni, C. Ray, and C. Claramunt, "Spatial models for context-aware indoor navigation systems: A survey," Journal of Spatial Information Science, pp. 85–123, May-2012.
- [54] P.-Y. Gilliéron and B. Merminod, "Personal navigation system for indoor applications," in 11th IAIN world congress, Berlin, 2003, pp. 1–15.
- [55] J. Latégahn, T. Ax, and C. Röhrig, "Multi hypothesis Kalman Filter for indoor pedestrian navigation based on topological maps," in 2016 IEEE/ION Position, Location and Navigation Symposium (PLANS), Savannah, GA, 2016, pp. 607–612.
- [56] C. Gaisbauer and A. U. Frank, "Wayfinding Model for Pedestrian Navigation," 11th AGILE International Conference on Geographic Information Science, University of Girona, Spain, 2008, pp. 1–9.
- [57] W. G. van Toll, A. F. Cook, and R. Geraerts, "A navigation mesh for dynamic environments," Comput. Animat. Virtual Worlds, vol. 23, no. 6, pp. 535–546, Nov. 2012.
- [58] M. Kallmann and M. Kapadia, "Navigation meshes and real-time dynamic planning for virtual worlds," in ACM SIGGRAPH 2014 Courses on - SIGGRAPH '14, 2014, pp. 1–81.
- [59] I. Afyouni, C. Ray, and C. Claramunt, "Spatial models for context-aware indoor navigation systems: A survey," Journal of Spatial Information Science, no. 4, pp. 85–123, May 2012.
- [60] M. R. F. Mendonça, H. S. Bernardino, and R. F. Neto, "Stealthy Path Planning Using Navigation Meshes," in 2015 Brazilian Conference on Intelligent Systems (BRACIS), Natal, 2015, pp. 31-36.
- [61] Igor Borovikov, "Navigation Graph Generation," 2011. [Online]. Available: <https://www.gamedev.net/articles/programming/artificial-intelligence/navigation-graph-generation-r2805/>. [Accessed: 12-Jan-2019].
- [62] P. Hafner, T. Moder, M. Wieser, and T. Bernoulli, "Evaluation of smartphone-based indoor positioning using different Bayes filters," in International Conference on Indoor Positioning and Indoor Navigation (IPIN), Montbeliard-Belfort, 2013, pp. 1-10.
- [63] W. Van Toll, A. F. Cook IV, and R. Geraerts, "Navigation meshes for realistic multi-layered

- environments,” in IEEE International Conference on Intelligent Robots and Systems, San Francisco, CA, 2011, pp. 3526-3532.
- [64] W. Xu, L. Liu, S. Zlatanova, W. Penard, and Q. Xiong, “A pedestrian tracking algorithm using grid-based indoor model,” *Automation in Construction*, vol. 92, pp. 173–187, Aug. 2018.
- [65] T. Fetzer, F. Ebner, F. Deinzer, L. Köping, and M. Grzegorzec, “On Monte Carlo smoothing in multi sensor indoor localisation,” in 2016 International Conference on Indoor Positioning and Indoor Navigation, Alcalá de Henares, 2016, pp. 1-8.
- [66] T. Moder, K. Wisiol, P. Hafner, and M. Wieser, “Smartphone-based Indoor Positioning Utilizing Motion Recognition,” 2015 International Conference on Indoor Positioning and Indoor Navigation (IPIN), Banff, AB, 2015, pp. 1-8.
- [67] S. Kaiser and C. Lang, “Detecting elevators and escalators in 3D pedestrian indoor navigation,” 2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN), Alcalá de Henares, 2016, pp. 1-6.
- [68] J. Wang, A. Hu, X. Li, and Y. Wang, “An Improved PDR/Magnetometer/Floor Map Integration Algorithm for Ubiquitous Positioning Using the Adaptive Unscented Kalman Filter,” *ISPRS Int. J. Geo-Information*, vol. 4, no. 4, pp. 2638–2659, 2015.
- [69] S.-W. Lee and K. Mase, “Activity and location recognition using wearable sensors,” in IEEE Pervasive Computing, vol. 1, no. 3, pp. 24-32, July-Sept. 2002.
- [70] I. Spassov, “Algorithms for map-aided autonomous indoor pedestrian positioning and navigation,” École Polytechnique Federale de Lausanne, Lausanne, Switzerland, 2007.
- [71] N. Kroll, J. Michael, and S. Sebastian, “Context-aware Indoor-Outdoor Detection for Seamless Smartphone Positioning,” in *GEOProcessing 2016: The Eighth International Conference on Advanced Geographic Information Systems, Applications, and Services*, Venice, Italy, 2016, pp. 106–108.
- [72] P. Zhou, Y. Zheng, Z. Li, M. Li, and G. Shen, “IODetector,” in *Proceedings of the 10th ACM Conference on Embedded Network Sensor Systems - SenSys '12*, Toronto, 2012, pp. 1-14.
- [73] W. Wang, Q. Chang, Q. Li, Z. Shi, and W. Chen, “Indoor-outdoor detection using a smart phone sensor,” *Sensors (Switzerland)*, vol. 16 (10), no. 563, Sep. 2016, pp. 1-15.
- [74] H. Gao and P. D. Groves, “Environmental Context Detection for Adaptive Navigation using GNSS Measurements from a Smartphone,” *Navigation, Journal of the Institute of Navigation*, vol. 65, no. 1, Wiley-Blackwell, pp. 99–116, 26-Feb-2018.
- [75] H. Jia, S. Su, W. Kong, H. Luo, and G. Shang, “MobiIO: Push the limit of indoor/outdoor detection through human’s mobility traces,” 2014 International Conference on Indoor Positioning and Indoor Navigation (IPIN), Busan, 2014, pp. 197-202.
- [76] T. Martire, P. Nazemzadeh, A. Cristiano, A. Sanna, and D. Trojaniello, “Indoor-Outdoor Detection using Head-mounted Color Light Sensors,” *GNB 2018 – Sixth National Congress of Bioengineering*, Milan, 2018, pp. 1-4.
- [77] R. Sung, S. hoon Jung, and D. Han, “Sound based indoor and outdoor environment detection for seamless positioning handover,” *ICT Express*, vol. 1, no. 3, pp. 106–109, Dec. 2015.
- [78] J. Krumm and R. Hariharan, “Tempio: inside/outside classification with temperature,” *Second International Workshop on Man-Machine Symbiotic Systems*, Kyoto, Dec. 2004, pp. 241–250.
- [79] G. Shtar, B. Shapira, and L. Rokach, “Clustering Wi-Fi fingerprints for indoor--outdoor detection,” *Wireless Networks*, pp.1-19, 2018.
- [80] M. Wu, P. H. Pathak, and P. Mohapatra, “Monitoring building door events using barometer sensor in smartphones,” in *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing - UbiComp '15*, Osaka, 2015, pp. 319–323.
- [81] V. Radu, P. Katsikouli, R. Sarkar, and M. K. Marina, “A semi-supervised learning approach for robust indoor-outdoor detection with smartphones,” in *Proceedings of the 12th ACM Conference on Embedded Network Sensor Systems - SenSys '14*, Memphis, 2014, pp. 1–15.
- [82] G. Louppe, “Understanding Random Forests: From Theory to Practice,” University of Liège, Faculty of Applied Sciences, Department of Electrical Engineering & Computer Science, July 2014.

- [83] “Understanding the Bias-Variance Tradeoff.” [Online]. Available: <http://scott.fortmann-roe.com/docs/BiasVariance.html>. [Accessed: 11-Sep-2018].
- [84] H. He and E. A. Garcia, “Learning from imbalanced data,” *IEEE Trans. Knowl. Data Eng.*, vol. 21, no. 9, pp. 1263–1284, Sep. 2009.
- [85] J. Jenness and J. J. Wynne, “Cohen’s Kappa and classification table metrics 2.0: An ArcView 3. x extension for accuracy assessment of spatially explicit models,” *USGS Numbered Series*, no. 2005-1363, pp. 1-86, 2005.
- [86] M. Bekkar, H. K. Djemaa, and T. A. Alitouche, “Evaluation measures for models’ assessment over imbalanced data sets,” *Journal of Information Engineering and Applications*, vol. 3, n. 10, pp. 27-38, 2013.
- [87] R. Alejo, J. A. Antonio, R. M. Valdovinos, and J. H. Pacheco-Sánchez, “Assessments Metrics for Multi-class Imbalance Learning: A Preliminary Study,” *Pattern Recognition. MCPR 2013. Lecture Notes in Computer Science*, vol 7914, pp. 335–343, 2013.
- [88] J. A. Cox, C. D. James, and J. B. Aimone, “A Signal Processing Approach for Cyber Data Classification with Deep Neural Networks,” in *Procedia Computer Science*, vol. 61, pp. 349–354, 2015.
- [89] “e1071 package | R Documentation.” [Online]. Available: <https://www.rdocumentation.org/packages/e1071/versions/1.7-0>. [Accessed: 11-Sep-2018].
- [90] A. L. Blum and P. Langley, “Selection of relevant features and examples in machine learning,” *Artificial Intelligence*, vol. 97, no. 1–2, pp. 245–271, Dec. 1997.
- [91] P. PREUX, “Fouille de données: Notes De Cours,” 2011. [Online]. Available: <http://www.grappa.univ-lille3.fr/~ppreux/Documents/notes-de-cours-de-fouille-de-donnees.pdf>. [Accessed: 12-01-2019].
- [92] J. Tang, S. Alelyani, and H. Liu, “Feature selection for classification: A review,” *Data Classification: Algorithms and Applications*, pp. 37-64, 2014.
- [93] T. N. Lal, O. Chapelle, J. Weston, and A. Elisseeff, “Embedded Methods,” in *Feature Extraction: Foundations and Applications*, I. Guyon, M. Nikraves, S. Gunn, and L. A. Zadeh, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 137–165, 2006.
- [94] C. Duby and S. Robin, “Analyse en composantes principales,” *Institut national de recherche agronomique - Paris Grignon*, pp. 1-54, 2006.
- [95] S. M. Holland, “Principal Components Analysis (PCA),” *University of Georgia*, pp. 1-11, 2008.
- [96] P. W. Mausel, W. J. Kramber, and J. K. Lee, “Optimum band selection for supervised classification of multispectral data,” *Photogramm. Eng. Remote Sensing*, vol. 56, no. 1, pp. 55–60, 1990.
- [97] M. Morchid, R. Dufour, P. M. Bousquet, G. Linares, and J. M. Torres-Moreno, “Feature selection using Principal Component Analysis for massive retweet detection,” *Pattern Recognit. Lett.*, vol. 49, pp. 33–39, Nov. 2014.
- [98] Q. Gu, Z. Li, and J. Han, “Generalized Fisher Score for Feature Selection,” *Proceedings of the 27th Conference on Uncertainty in Artificial Intelligence*, Feb. 2012, pp. 1-8.
- [99] J. R. Vergara and P. A. Estévez, “A review of feature selection methods based on mutual information,” *Neural Computing and Applications*, vol. 24, n. 1, pp. 175-186, January 2014.
- [100] M. Elhoushi, S. Member, J. Georgy, A. Noureldin, S. Member, and M. J. Korenberg, “Motion Mode Recognition for Indoor Pedestrian Navigation Using Portable Devices for Indoor Pedestrian Navigation Using Portable Devices,” in *IEEE Transactions on Instrumentation and Measurement*, vol. 65, no. 1, pp. 208-221, Jan. 2016.
- [101] F. T. Alaoui, V. Renaudin, and D. Betaille, “Points of interest detection for map-aided PDR in combined outdoor-indoor spaces,” in *2017 International Conference on Indoor Positioning and Indoor Navigation*, Sapporo, 2017.
- [102] P. Senin, “Literature Review on Time Series Indexing,” *Collaborative Software Development Lab, Department of Information and Computer Sciences, University of Hawaii*, pp. 1-33, April 2009.
- [103] “Signal envelope - MATLAB envelope - MathWorks France.” [Online]. Available: <https://fr.mathworks.com/help/signal/ref/envelope.html>. [Accessed: 06-Apr-2018].

- [104] “Envelope Detection - MATLAB” [Online]. Available: <https://fr.mathworks.com/help/dsp/examples/envelope-detection.html>. [Accessed: 06-Apr-2018].
- [105] A. Mueen and E. Keogh, “Extracting Optimal Performance from Dynamic Time Warping,” in Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16, San Francisco, 2016, pp. 2129–2130.
- [106] H. Skutkova, M. Vitek, P. Babula, R. Kizek, and I. Provaznik, “Classification of genomic signals using dynamic time warping,” BMC Bioinformatics, vol. 14, Suppl. 10, pp. 1-7, 2013.
- [107] T. M. Rath and R. Manmatha, “Lower-Bounding of Dynamic Time Warping Distances for Multivariate Time Series,” pp. 1–4, 2003.
- [108] M. S. Arulampalam, S. Maskell, N. Gordon, and T. Clapp, “A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking,” in IEEE Transactions on Signal Processing, vol. 50, no. 2, pp. 174-188, Feb. 2002.
- [109] J.-M. Brossier and P.-O. Amblard, “Particulaire et communications numériques,” SEE, École Nationale Supérieure d'Ingénieurs Electriciens de Grenoble (LIS/ENSIEG), June 2004.
- [110] L. Bazzani, D. Bloisi, and V. Murino, “A Comparison of Multi Hypothesis Kalman Filter and Particle Filter for Multi-target Tracking,” In Eleventh IEEE International Workshop on Performance Evaluation of Tracking and Surveillance, Florida, 2009, pp. 1-8.
- [111] P. Bonnifait, J. Laneurit, C. Fouque, and G. Dherbomez, “Multi-hypothesis map-matching using particle filtering,” in 16th World Congress for ITS Systems and Services, Stockholm, 2009, pp. 1–8.
- [112] T. Willemsen, F. Keller, and H. Sternberg, “A topological approach with MEMS in smartphones based on routing-graph,” in Indoor Positioning and Indoor Navigation (IPIN), Banff, 2015, pp. 1–6.
- [113] F. T. Alaoui, D. Betaille and V. Renaudin, "A multi-hypothesis particle filtering approach for pedestrian dead reckoning," 2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN), Alcalá de Henares, 2016, pp. 1-8.
- [114] P. Hafner, T. Moder, M. Wieser, and T. Bernoulli, “Evaluation of Smartphone-based Indoor Positioning Using Different Bayes Filters,” in International Conference on Indoor Positioning and Indoor Navigation (IPIN), Montbeliard-Belfort, 2013, pp. 1-10.
- [115] A. Selloum, “Localisation multi-capteurs d'un véhicule routier sous contraintes cartographiques : Mise en oeuvre d'un filtre particulaire et d'une modélisation multi-voies de la route par des clothoïdes,” PhD Thesis, LCPC/MACS - Département Mesure, Auscultation et Calcul Scientifique, Centrale Nantes, November 2010.
- [116] Widyawan, M. Klepal, and S. Beauregard, “A Backtracking Particle Filter for fusing building plans with PDR displacement estimates,” 5th Workshop on Positioning, Navigation and Communication, Hannover, 2008, pp. 207-212.
- [117] H. Bao and W.-C. Wong, “An indoor dead-reckoning algorithm with map matching,” 9th International Wireless Communications and Mobile Computing Conference (IWCMC), Sardinia, 2013, pp. 1534-1539.
- [118] “factoextra package Readme | R Documentation.” [Online]. Available: <https://www.rdocumentation.org/packages/factoextra/versions/1.0.3/readme>. [Accessed: 13-Sep-2018].
- [119] “discretize function | R Documentation.” [Online]. Available: <https://www.rdocumentation.org/packages/infotheo/versions/1.2.0/topics/discretize>. [Accessed: 17-Aug-2018].
- [120] M. Susi, “Gait Analysis for Pedestrian Navigation Using MEMS Handheld Devices,” Master of Science Thesis, Department of Geomatics Engineering, Calgary, Alberta, September 2012.
- [121] “RTKLIB: An Open Source Program Package for GNSS Positioning,” [Online]. Available: <https://www.rtklib.com/>. [Accessed: 13-Jan-2019].
- [122] U. M. Fayyad and K. B. Irani, “Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning,” In the Thirteenth International Joint Conference on Artificial Intelligence. San Francisco, Sep. 1993, pp. 1022–1027.
- [123] D. Steinberg, “Chapter 10: CART: Classification and Regression Trees,” CRC Press, Boca Raton,

- FL. The Top Ten Algorithms in Data Mining, pp. 179–201, 2009.
- [124] S. L. Crawford, “Extensions to the CART algorithm,” *International Journal of Man-Machine Studies*, vol. 31, no. 2, pp. 197–217, Aug. 1989.
- [125] “Data Science Basics: An Introduction to Ensemble Learners.” [Online]. Available: <https://www.kdnuggets.com/2016/11/data-science-basics-intro-ensemble-learners.html>. [Accessed: 06-Aug-2018].
- [126] W. Buntine, “Decision Tree Induction Systems: A Bayesian Analysis,” in *UAI’87 Proceedings of the Third Conference on Uncertainty in Artificial Intelligence*, 1989, pp. 109–127.
- [127] L. Breiman, “Random forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [128] A. Ben-Hur and J. Weston, “A user’s guide to support vector machines,” *Data Mining Techniques for the Life Sciences. Methods in Molecular Biology (Methods and Protocols)*, vol. 609, pp. 223–239, 2010.
- [129] “AI - Ch17 - Support vector machine, SVM | Mr. Opengate.” [Online]. Available: <http://mropengate.blogspot.com/2015/03/support-vector-machines-svm.html>. [Accessed: 13-Jan-2019].

ANNEXES

I. ANNEXE 1 : PROBABILITES CONDITIONNELLES	142
I.1 Loi d'une Variable Aléatoire Continue (VAC)	142
I.2 Espérance d'une VAC	142
I.3 Support d'une VAC	142
I.4 Lois conjointe et marginale	142
I.5 Probabilité conditionnelle et loi de Bayes	143
I.6 Espérance conditionnelle	143
I.7 Indépendance conditionnelle	144
I.8 Loi des probabilités totales	144
II. ANNEXE 2 : DETAILS DES ALGORITHMES DE CLASSIFICATION	145
II.1 Random Forest	145
II.1.1 Principe des arbres de décision	145
II.1.2 Critères d'homogénéité	145
II.1.3 Création des branches à partir d'un nœud/descripteur	147
II.1.4 Arbres de décision usuels : ID3, C4.5 et CART	148
II.1.5 Le Bagging	149
II.1.6 Spécificités de l'algorithme RF	150
II.2 Réseaux de neurones	150
II.2.1 Notations	150
II.2.2 Fonctionnement d'un neurone	151
II.2.3 Apprentissage avec un réseau de neurones (Artificial Neural Network : ANN)	152
II.3 Séparateurs à Vaste Marge (SVM)	153
II.3.1 Définitions	153
II.3.2 SVM linéaires	155
II.3.3 SVM non linéaires	157

I. ANNEXE 1 : Probabilités conditionnelles

I.1 Loi d'une Variable Aléatoire Continue (VAC)

Soient $d \in \mathbb{N}^*$ et $\mathbf{X} \subset \mathbb{R}^d$. Soit $X \in \mathbf{X}$ une VAC ayant pour fonction de répartition la fonction $F_X : \mathbb{R}^d \rightarrow \mathbb{R}^+$ qui s'écrit $\forall x \in \mathbb{R}^d : F_X(x) = P(X_1 \leq x_1, \dots, X_d \leq x_d)$ où P signifie 'Probabilité'.

$X = x$ signifie que la variable X a pris la valeur x , on dit alors que x est une réalisation de X . $X \leq x$ signifie que la réalisation de X est inférieure à x .

X admet une densité de probabilité s'il existe une fonction $p_X : \mathbf{X} \rightarrow \mathbb{R}^+$ telle que :

$$\forall A \subset \mathbf{X} : P(X \in A) = \int_A p_X(x).dx$$

La densité de probabilité p_X vérifie les propriétés suivantes :

$$\forall x \in \mathbf{X} \left\{ \begin{array}{l} p_X(x) \geq 0 \\ \int_{\mathbf{X}} p_X(x).dx = 1 \end{array} \right.$$

La loi de X est définie par l'ensemble des valeurs possibles de X ainsi que par leur densité de probabilité.

I.2 Espérance d'une VAC

Soit g une fonction définie sur $S(X)$ à valeurs numériques. L'espérance est un opérateur qui, si l'intégrale $\int_{\mathbf{X}} g(x)p_X(x).dx$ est convergente, retourne la valeur :

$$E[g(X)] = \int_{\mathbf{X}} g(x)p_X(x).dx$$

I.3 Support d'une VAC

Le support de X est l'ensemble des valeurs $\{x \in \mathbf{X}\}$ pour lesquelles $p_X(x) > 0$. Il est noté $S(X)$:

$$S(X) = \{x \in \mathbf{X} / p_X(x) > 0\}$$

I.4 Lois conjointe et marginale

$U = \begin{bmatrix} X \\ Y \end{bmatrix}$ est une VA composée des deux VA $X \in \mathbf{X}$ et $Y \in \mathbf{Y}$. La loi de U est appelée loi

« conjointe ». Si cette dernière admet une densité de probabilité $p_{X,Y} : \mathbf{X} \times \mathbf{Y} \rightarrow \mathbb{R}^+$, alors on a $\forall A \subset \mathbf{X} \times \mathbf{Y}$:

$$P((X, Y) \in A) = \int_A p_{X,Y}(x, y).dx.dy$$

La loi conjointe vérifie la propriété suivante :

$$\forall (x, y) \in \mathbf{X} \times \mathbf{Y} : p_{X,Y}(x, y) = p_{Y,X}(y, x)$$

Le fait de ne s'intéresser qu'à une seule composante de la variable U revient à étudier sa loi dite « marginale ». Sa densité de probabilité peut être déduite de la loi conjointe par la formule :

$$p_X(x) = \int_Y p_{X,Y}(x, y).dy$$

I.5 Probabilité conditionnelle et loi de Bayes

Lorsque l'on souhaite étudier la loi de X connaissant la réalisation y de la variable Y , cela est modélisé par une loi conditionnelle (par opposition avec la loi marginale). Si la loi conditionnelle de X sachant Y admet une densité de probabilité $p_{X|Y} : \mathbf{X} \times S(Y) \rightarrow R^+$, alors on a :

$$\begin{aligned} \forall E = \{A(y) \subset \mathbf{X} / y \in S(Y)\} \\ P(X \in E | Y = y) = \int_E p_{X|Y}(x, y).dx \end{aligned}$$

Le support de la loi de $X | Y$ est donné par :

$$\forall y \in S(Y) : S(X | Y = y) = \{x \in \mathbf{X} / p_{X|Y}(x, y) > 0\}$$

La loi conditionnelle peut être calculée à partir de la loi conjointe par simple normalisation :

$$p_{X|Y}(x, y) = \frac{p_{X,Y}(x, y)}{\int_{\mathbf{X}} p_{X,Y}(x, y).dx}$$

or, d'après l'équation précédente:

D'où :

$$\frac{p_{X,Y}(x, y)}{\int_{\mathbf{X}} p_{X,Y}(x, y).dx} = \frac{p_{X,Y}(x, y)}{p_Y(y)}, \quad p_{X|Y}(x, y) = \frac{p_{X,Y}(x, y)}{p_Y(y)}$$

En inversant X et Y on peut écrire :

D'où la loi de Bayes :

$$p_{Y|X}(y, x) = \frac{p_{X,Y}(x, y)}{p_X(x)}, \quad p_{Y|X}(y, x) = \frac{p_{X|Y}(x, y).p_Y(y)}{p_X(x)}$$

I.6 Espérance conditionnelle

Soit $g : \mathbf{X} \times S(Y) \rightarrow I$ une fonction à valeurs numériques. L'espérance conditionnelle de $g(X, Y) | Y$ est donnée par :

$$\forall (x, y) \in \mathbf{X} \times S(Y) : E[g(X, Y) | Y = y] = \int_{\mathbf{X}} g(x, y)p_{X|Y}(x, y).dx$$

I.7 Indépendance conditionnelle

Considérons une 3^{ème} VA $Z \subset \mathbb{R}^d$. On dit que X et Y sont indépendantes conditionnellement à Z si :

$$p_{X,Y|Z} = p_{X|Z} \cdot p_{Y|Z}$$

Ou si :

$$p_{X,Y|Z} = p_{X|Z} \cdot p_{Y|Z} \Leftrightarrow p_{X|Y,Z} = p_{X|Z}$$

Cette propriété est notée $X \perp Y | Z$.

I.8 Loi des probabilités totales

Il est possible à partir des probabilités conditionnelle et conjointe de calculer la loi marginale de Y conformément à la loi des probabilités totales définie par :

$$\forall (x, y) \in S(X) \times S(Y) : p_Y(y) = \int_{S(X)} p_X(x) \cdot p_{Y|X}(y, x) \cdot dx$$

Cette loi est utilisée dans le calcul de la densité a posteriori de l'état dans le filtrage Bayésien.

II. ANNEXE 2 : Détails des algorithmes de classification

II.1 Random Forest

L'algorithme RF est issu de la combinaison de plusieurs arbres de décision pour former un classifieur unique et plus performant que chacun des arbres de décision pris à part. Cette section présente le principe des arbres de décision, la méthode de leur agrégation pour finir sur les spécificités de l'algorithme Random Forest utilisé dans nos travaux.

II.1.1 Principe des arbres de décision

Un arbre de décision est un graphe constitué de nœuds reliés par des branches. Dans une approche « top-down », la construction de l'arbre débute à son sommet, appelé nœud racine. Ce dernier regroupe tous les individus d'apprentissage. Il correspond par ailleurs au premier descripteur choisi, selon un critère donné, pour réaliser un test et diviser les individus d'apprentissage en sous-partitions appelées nœuds enfants. En effet, les nœuds enfants sont des partitions $(\lambda_{l \in [1, q]})$ optimales suivant un critère d'homogénéité vis-à-vis de la variable cible, à savoir la variable « classe ». Autrement dit, une partition est optimale si la diversité des classes des individus y appartenant est minimale. Ce processus est itératif et s'arrête généralement lorsqu'aucune division n'est plus possible, ou lorsque le nombre minimal d'individus au sein d'un nœud est atteint. Au terme des différentes divisions, l'arbre de décision présente une structure verticalement hiérarchisée de nœuds parents-enfants appelés nœuds internes, ainsi que des nœuds terminaux appelés également « feuilles » (Figure 108). Chaque feuille est affectée à une classe, usuellement celle qui est majoritaire au sein du nœud terminal (E. 132). Pour prédire la classe d'un nouvel individu, ce dernier doit passer les tests de l'arbre à partir du nœud racine jusqu'à une feuille terminale qui déterminera sa classe.

Se pose alors la question du critère d'optimisation des partitions ainsi que celle de l'ordre des descripteurs à tester, c'est-à-dire la hiérarchie verticale des nœuds. La réponse à ces deux questions se trouve dans l'expression des critères d'homogénéité présentés dans la section suivante.

$$f(\mathbf{x}) = \hat{y} = \arg \max_k p(y = y_k | \mathbf{x} \in \lambda_l) \quad \text{E. 132}$$

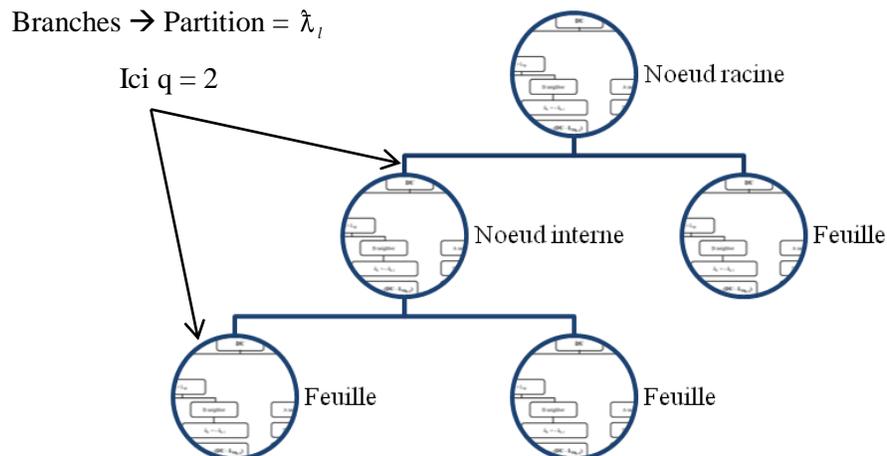


Figure 108 : Terminologie des arbres de décision

II.1.2 Critères d'homogénéité

Nous rappelons d'abord que la probabilité d'une classe k au sein d'une partition λ_l est définie comme :

$$p_k(\lambda_l) = p(y = y_k \mid \mathbf{x} \in \lambda_l)$$

Cette entité peut être déterminée numériquement dès lors qu'une division est réalisée par :

$$p_k(\lambda_l) = \frac{\text{Card}(\{y = y_k \mid \mathbf{x} \in \lambda_l\})}{\text{Card}(\lambda_l)}$$

Nous présentons ci-après 3 critères d'homogénéité qui sont exploités dans la création d'arbres de décision usuels. Ces notions valent à la fois comme outils de décision sur quel descripteur est optimal à l'étape courante, comment le partitionner et à quel moment arrêter sa division. Pour ce faire nous nous situons au nœud-parent A ayant pour éventuels nœuds enfants l'ensemble des partitions $Ens(A) = \lambda_{l \in [1, q]}$. Pour simplifier les notations, sauf nécessité, nous substituons la notation $A(j)$, qui signifie « descripteur j testé au nœud A », par A .

- Index Gini

L'indice de Gini de la partition λ_l s'écrit :

$$\text{Gini}(\lambda_l) = 1 - \sum_{k=1}^K (p_k(\lambda_l))^2$$

L'indice de Gini traduit l'hétérogénéité au sein d'une partition. Il est compris entre 0 et 1. Ainsi, idéalement, tous les individus d'une partition appartiennent à la même classe et l'indice de Gini vaut 0.

Il peut également être défini pour un ensemble de partitions $Ens(A) = \lambda_{l \in [1, q]}$ issu du nœud parent A tel que :

$$\begin{aligned} \text{Gini}(Ens(A)) &= \sum_{l=1}^q P(\lambda_l) \text{Gini}(\lambda_l) \\ P(\lambda_l) &= \frac{\text{Card}(\lambda_l)}{\text{Card}(A)} \end{aligned}$$

qui n'est rien d'autre que la moyenne pondérée des indices de Gini de chaque partition. Aussi, le descripteur présentant un indice de Gini minimal après division est retenu pour constituer les branches succédant au nœud courant. Pour un nombre p de descripteurs, celui qui est optimal est donné par :

$$j_{opt} = \arg \min_{j \in [1, p]} \text{Gini}(Ens(A(j)))$$

- Entropie de Shannon

L'entropie de Shannon de la partition λ_l s'écrit :

$$H(\lambda_l) = - \sum_{k=1}^K p_k(\lambda_l) \ln(p_k(\lambda_l))$$

Pour l'ensemble $Ens(A) = \lambda_{l \in [1, q]}$ issu de la division du nœud parent A , l'entropie de Shannon équivalente est :

$$H(Ens(A)) = \sum_{l=1}^q P(\lambda_l) H(\lambda_l) \quad \text{E. 133}$$

L'entropie de Shannon traduit le désordre ou la dispersion au sein d'un ensemble. Contrairement à l'indice de Gini, le maximum atteint par l'entropie dépend du nombre de classes. Ici l'entropie traduit la dispersion des classes au sein d'une partition ou d'un ensemble de partitions. Dans la théorie de l'information, l'entropie est considérée comme l'information contenue dans l'ensemble. Etant donné le but recherché dans le cas des arbres de décision, il s'agit de trouver l'ensemble qui présente le moins d'entropie possible. Pour ce faire, les algorithmes classiques utilisent le gain d'information qui s'écrit :

- Gain d'information

$$G_{Ens(A)} = H(A) - H(Ens(A))$$

Il s'agit en effet de la comparaison de l'entropie avant et après division du nœud parent A . L'entropie après division est approchée par la moyenne pondérée de l'entropie au sein de chaque nœud-enfant (E. 133). Si cette dernière est plus faible, alors le gain est positif et le partitionnement est efficace car il assure davantage d'homogénéité au sein des nouvelles partitions. Si elle est plus importante, alors le partitionnement est contre-productif et le gain est négatif.

- Ratio du gain

Bien qu'étant pertinent, le gain d'information a l'inconvénient de favoriser les variables descriptives pour lesquelles il y a un grand nombre de valeurs possibles et donc de partitions possibles. Il est donc considéré comme un estimateur biaisé. Pour pallier ce phénomène, le ratio du gain a été introduit. Il divise le gain d'information par le nombre et la taille des partitions créées afin de réaliser une certaine normalisation qui permettrait de traiter les descripteurs de manière plus équitable. Le facteur de normalisation, appelé information intrinsèque, n'est rien d'autre que l'entropie de l'ensemble des partitions, sauf que la variable cible de l'entropie n'est pas la classe mais la partition elle-même:

$$SplitInfo_{Ens(A)} = -\sum_{l=1}^q P(\lambda_l) \ln(P(\lambda_l))$$

Le ratio du gain correspond alors à :

$$RG_{Ens(A)} = \frac{G_{Ens(A)}}{SplitInfo_A}$$

- Erreur de classification

$$E(\lambda_l) = 1 - \max_k p_k(\lambda_l)$$

Cette statistique donne en effet le taux d'erreur de classification. Puisque $\max_k p_k(\lambda_l)$ est la probabilité de la classe majoritaire au sein de la partition λ_l , calculer $E(\lambda_l)$ revient à évaluer la probabilité des classes restantes au sein de la partition. Evidemment l'erreur est de 0 si tous les individus sont de même classe, et, au pire des cas, égale à $1 - \frac{1}{K}$ si la distribution des classes au sein de la partition est uniforme.

II.1.3 Création des branches à partir d'un nœud/descripteur

Avant d'évaluer la pertinence des partitions il faut dans un premier temps les créer. La division d'un nœud-parent en nœuds enfants se fait trivialement en créant autant de branches que de valeurs possibles lorsque le descripteur est nominal. Ce n'est pas aussi évident lorsque les variables descriptives sont continues/numériques. Il faut généralement passer par une étape de discrétisation. Cela peut être réalisé par exemple par dichotomie (division binaire) selon un seuil appelé point de coupure (cut-point), ou bien par la création de plusieurs sous-intervalles. Dans les deux cas, la discrétisation doit s'opérer de manière optimale, en minimisant l'entropie de l'ensemble des partitions créées par exemple [122]. Rappelons que

l'entropie d'un ensemble de partitions est approchée par la moyenne pondérée des entropies de chacune des partitions de l'ensemble. Dans une approche dichotomique, les auteurs de [122] démontrent notamment que le point de coupure qui minimise le critère d'entropie $H(Ens(A))$ se trouve nécessairement à la frontière entre deux individus de classes distinctes (Figure 109, points B1 et B2). En d'autres termes, si le nœud parent A qui contient N valeurs distinctes a été divisé selon le point de coupure d'indicatrice T en deux partitions constituant l'ensemble :

$$Ens(A, T) = \{\tilde{\lambda}_1^T, \tilde{\lambda}_2^T\}$$

alors le point de coupure optimal T correspond à :

$$T_{opt} = \arg \min_T \{H(Ens(A, T))_{T \in [1, N]}\}$$

tel que :

$$H(Ens(A, T)) = \sum_{l=1}^2 P(\tilde{\lambda}_l^T) H(\tilde{\lambda}_l^T)$$

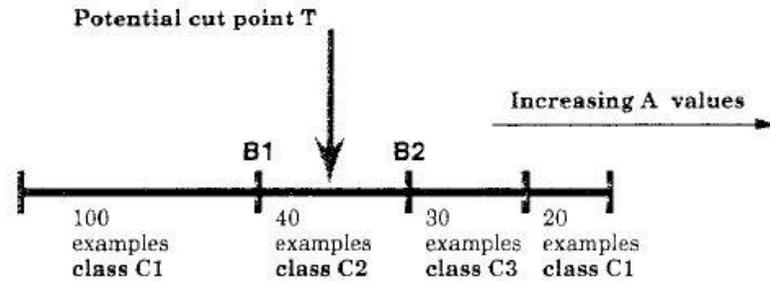


Figure 109 : Points de coupure pour partitionner le nœud/descripteur A après tri des individus dans l'ordre croissant [122]

Les auteurs rapportent également que discrétiser un descripteur selon un nombre supérieur à deux partitions permet d'obtenir des arbres de décision moins complexes (car plus petits) et plus optimaux en termes de risque empirique²⁵ de mis-classification. Dans ce cas, la division en plusieurs intervalles se fait selon l'approche dichotomique de manière itérative. Ce postulat n'est toutefois pas admis de manière universelle et parfois une dichotomie binaire est privilégiée comme dans l'algorithme CART [123].

Dans le cas d'une dichotomie itérative, la méthode consiste à décider de continuer ou non de partitionner les nœuds enfants retenus à chaque itération. Sans nous attarder sur la théorie permettant d'obtenir ce critère d'arrêt [122], nous retiendrons que ce dernier est donné par une condition théorique appliquée au gain d'information obtenu après dichotomie de la partition A en deux sous-partitions $Ens(A, T_{opt}) = \{\tilde{\lambda}_1^{T_{opt}}, \tilde{\lambda}_2^{T_{opt}}\}$ selon le point de coupure optimal T_{opt} . Cette condition s'écrit :

$$G_{Ens(A, T_{opt})} > \frac{\ln(n-1)}{n} + \frac{\Delta(A, Ens(A, T_{opt}))}{n}$$

$$\Delta(A, Ens(A, T_{opt})) = \ln(3^K - 2) - \left[K \times H(A) - Card(\tilde{\lambda}_1^{T_{opt}}) \times H(\tilde{\lambda}_1^{T_{opt}}) - Card(\tilde{\lambda}_2^{T_{opt}}) \times H(\tilde{\lambda}_2^{T_{opt}}) \right]$$

Si cette condition est vérifiée la division est admise, sinon elle est rejetée et cela aboutit à un nombre maximal de nœuds enfants issus du nœud A portant le descripteur j .

II.1.4 Arbres de décision usuels : ID3, C4.5 et CART

²⁵ A distinguer du risque réel. Le risque empirique est le taux d'erreur de classification estimé empiriquement à partir des données disponibles. Le risque réel ne peut être connu étant donné l'étendue limitée des données d'apprentissage (Voir théorie de Vapnik-Chervonenkis).

- **ID3**: Gain d'information

Dans l'algorithme ID3, pour décider du descripteur à tester au nœud courant A , l'ensemble des descripteurs sont partitionnés suivant leurs valeurs nominales. En effet, l'algorithme ID3 est fait pour des variables descriptives catégorielles, ou du moins discrètes. Pour chaque descripteur, le gain d'information est calculé à la suite de sa division en partitions. Le descripteur ayant le gain maximal est retenu.

$$j_{opt} = \arg \min_{j \in [1, p]} G_{Ens(A, T_{opt})}$$

ce qui permet à la fois de réaliser le choix d'un descripteur optimal, mais aussi un nombre et une disposition de partitions optimaux vis-à-vis de la variable classe.

Une fois que les partitions sont créées, chaque nœud enfant devient candidat à être un nouveau nœud parent. Un nouveau test sur un descripteur non-encore utilisé est créé de la même manière. L'arrêt de l'algorithme se fait lorsque l'ensemble des descripteurs ont été testés.

- **C4.5** : Ratio du gain + Erreur de classification

L'algorithme C4.5 est une extension de ID3 introduite pour pallier le biais du gain d'information en optimisant le ratio du gain d'information. Il permet également de gérer les variables continues. Ainsi l'ensemble des descripteurs sont partitionnés conformément aux règles de la section II.1.3 selon une dichotomie itérative de préférence. Une troisième amélioration réalisée par l'algorithme C4.5 consiste en l'élagage (post-pruning) de l'arbre de décision. Cette opération consiste à supprimer les sous arbres (ensemble de partitions + leur nœud racine) par des feuilles si le taux d'erreur présenté par le sous arbre est supérieur à celui qui aurait été obtenu à partir du nœud racine, ce qui suppose une validation avec un jeu de données test. Grâce à cette opération, non seulement l'erreur de prédiction est diminuée, mais la complexité de l'arbre l'est aussi puisque sa taille est diminuée, et le problème de sur-apprentissage est également prévenu grâce à la diminution de la complexité de l'arbre de décision.

- **CART** :

L'algorithme CART utilise une dichotomie binaire (Figure 110). Sous certaines conditions de concavité, cet algorithme est insensible au choix du critère d'homogénéité [124]. Il est cependant souvent utilisé avec l'index Gini [123] qui permet de générer des partitions de tailles comparables. Le critère d'arrêt dans la plupart des implémentations de l'algorithme CART consiste en un nombre minimal d'individus par nœud.

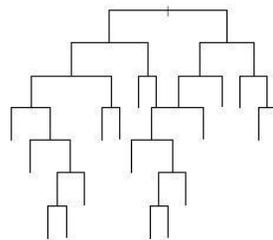


Figure 110 : Structure d'un arbre de décision construit par l'algorithme CART

II.1.5 Le Bagging

Le Bagging, équivalent de « Bootstrap & aggregation », est une méthode d'ensemble qui consiste à créer plusieurs prédicteurs et à les agréger dans le but d'en diminuer l'erreur de généralisation (notamment la composante *variance*). Le principe du Bootstrap (Figure 111) consiste à former M ensembles d'apprentissage $\{L_m\}_{m \in [1, M]}$ appelés « Bootstrap » à partir de l'ensemble initial L selon la condition $Card(L) = Card(L_m)$, c'est-à-dire que chacun des bootstraps contient autant d'individus que l'ensemble initial L . Le tirage des individus se fait selon une loi uniforme avec remise, ce qui a pour

conséquence qu'en moyenne 37% des individus appartenant à L sont manquants dans L_m [82]. Les ensembles $\{L_m\}_{m \in [1, M]}$ sont toutefois supposés de même distribution. Le fait d'introduire de l'aléa dans la sélection des individus d'apprentissage permet au processus d'agrégation de former un prédicteur final qui est plus stable car il est issu d'ensembles d'apprentissage différents.

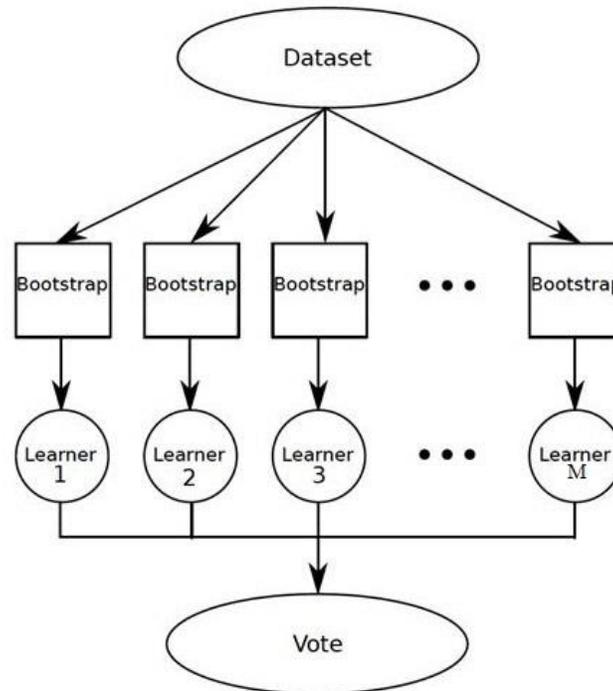


Figure 111 : Principe du Bagging dans le cas de la classification [125]

II.1.6 Spécificités de l'algorithme RF

Dans la littérature le terme « random forest » correspond à tout modèle issu d'une agrégation d'arbres de décision et il en existe plusieurs variantes qui sont des améliorations successives de l'algorithme initialement développé dans [126]. Lorsque les initiales de Random Forest sont en majuscules cela désigne l'algorithme développé par Breiman en 2001 [127]. Il repose à la fois sur l'introduction d'aléa dans la sélection des individus d'apprentissage mais aussi au niveau des variables descriptives. Cela permet notamment d'introduire une plus grande variance au sein des arbres de décision et de profiter de leur agrégation pour la réduire. Il se déroule comme suivant:

- Création de M ensembles d'apprentissage (Bootstraps).
- Sélection aléatoire de $M_{try} < p$ descripteurs selon une loi uniforme à chaque nœud de l'arbre en cours.
- Choix du nombre minimal d'individus par nœud comme critère d'arrêt pour la construction des arbres.
- Calcul des M arbres de décision selon l'algorithme CART.
- Choix de la classe au moyen d'un vote majoritaire.

II.2 Réseaux de neurones

II.2.1 Notations

La Figure 112 représente la connexion entre deux neurones. Les notations adoptées sont explicitées ci-

dessous :

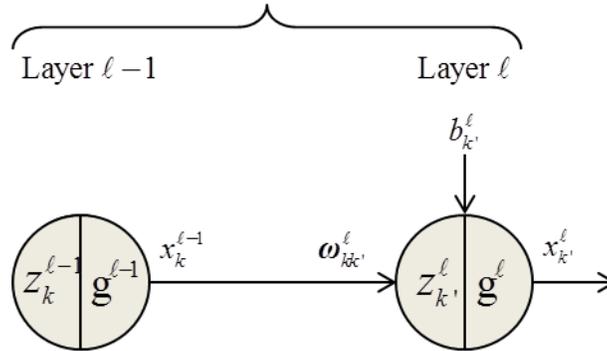


Figure 112 : Notations pour les variables de transfert entre deux couches

- ℓ est un indice de couche.
- (k, k') sont les indices respectifs de neurones de deux couches successives.
- x_k^ℓ est la sortie du neurone k de la couche ℓ . Elle est à valeur réelle.
- z_k^ℓ est une variable intermédiaire du neurone k de la couche ℓ . Elle est à valeur réelle.
- g^ℓ est la fonction d'activation de la couche ℓ .
- $\omega_{kk'}^\ell$ est le poids affecté au neurone k de la couche $\ell - 1$ par le neurone k' de la couche ℓ .
- $b_{k'}^\ell$ est le biais du neurone k' de la couche ℓ .
- N_ℓ est le nombre de neurones de la couche ℓ .

II.2.2 Fonctionnement d'un neurone

Un neurone k' de la couche ℓ a pour rôle de transformer le vecteur $\mathbf{x}^{\ell-1} = [x_1^{\ell-1}, \dots, x_{N_{\ell-1}}^{\ell-1}]^T$ où $\forall k \in [1, N_{\ell-1}]$ $x_k^{\ell-1} \in \mathfrak{R}$ en une sortie $x_{k'}^\ell \in \mathfrak{R}$ (Figure 113). Le neurone contient un biais $b_{k'}^\ell \in \mathfrak{R}$ ainsi que $N_{\ell-1}$ valeurs de poids formant le vecteur $\boldsymbol{\omega} = [\omega_{1k'}^\ell, \dots, \omega_{N_{\ell-1}k'}^\ell]^T$. Le neurone est par ailleurs doté d'une fonction d'activation $g^\ell : \mathfrak{R} \rightarrow \mathfrak{R}$ qui est non linéaire. Ici nous prenons l'exemple de la fonction sigmoïde qui s'écrit $g(x) = \frac{1}{1 + e^{-x}}$. Le transfert de $\mathbf{x}^{\ell-1}$ à travers le neurone se fait selon le processus suivant :

- 1- Calculer $z_{k'}^\ell = b_{k'}^\ell + \sum_{k=1}^{N_{\ell-1}} \omega_{kk'}^\ell \cdot x_k^{\ell-1}$

Pour des raisons pratiques on peut fusionner le biais avec le vecteur poids pour obtenir une équation de la forme :

$$\begin{cases} b_{k'}^\ell = \omega_{0k'}^\ell \\ x_0^{\ell-1} = 1 \end{cases} \Rightarrow z_{k'}^\ell = \sum_{k=0}^{N_{\ell-1}} \omega_{kk'}^\ell \cdot x_k^{\ell-1}$$

- 2- Calculer $x_{k'}^\ell = g^\ell(z_{k'}^\ell)$

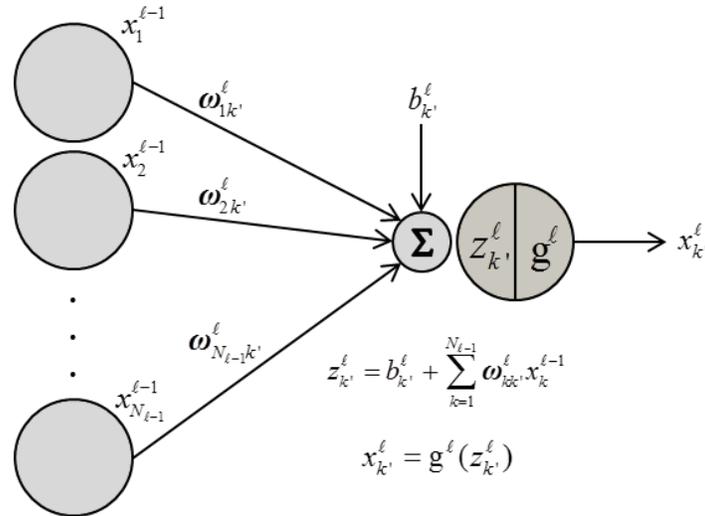


Figure 113 : Fonctionnement d'un neurone

II.2.3 Apprentissage avec un réseau de neurones (Artificial Neural Network : ANN)

▪ Principe de l'algorithme ANN

L'apprentissage avec un réseau de neurones repose sur deux phases : Une phase qui consiste à propager les individus d'apprentissage de la première à la dernière couche au moyen des équations de transfert précédentes, et une phase qui consiste à calculer l'erreur de propagation à la dernière couche puis à en déduire des corrections de poids de chacun des neurones du réseau en parcourant ce dernier en sens inverse. Cette seconde phase se fait au moyen d'une rétropropagation de gradient et c'est ce qui fait l'objet de cette section.

Commençons par introduire l'erreur de propagation à la dernière couche L . Elle est évaluée au moyen d'une fonction coût C s'écrivant usuellement :

$$E = C(x_k^L, t_k^L) = \frac{1}{2} (x_k^L - t_k^L)^2$$

où t_k^L est la valeur vraie de la sortie.

A partir de l'expression de cette erreur, l'algorithme de rétropropagation du gradient cherche à calculer le terme générique $\frac{\partial E}{\partial \omega_{kk}^l}$ pour tous les neurones de toutes les couches l afin de corriger chacun des poids du réseau selon l'équation:

$$\omega_{kk'}^{l(update)} = \omega_{kk'}^l - \gamma \frac{\partial E}{\partial \omega_{kk'}^l}$$

où γ est un paramètre appelé vitesse d'apprentissage (learning rate) qui permet d'ajuster le pas de la correction en fonction de l'erreur de propagation.

▪ Aspects calculatoires

Le calcul du terme générique $\frac{\partial E}{\partial \omega_{kk'}^l}$ repose sur les équations suivantes :

Initialisation à la dernière couche

On commence par calculer le gradient de l'erreur à la dernière couche L pour tout neurone k' . Les dérivées partielles sont calculées au moyen de la règle de Chasles comme suivant :

$$\frac{\partial E}{\partial \omega_{kk'}^L} = \frac{\partial E}{\partial x_{k'}^L} \frac{\partial x_{k'}^L}{\partial z_{k'}^L} \frac{\partial z_{k'}^L}{\partial \omega_{kk'}^L}$$

Avec les entités calculables suivantes :

$$\frac{\partial E}{\partial x_{k'}^L} = (x_{k'}^L - t_{k'}^L), \quad \frac{\partial x_{k'}^L}{\partial z_{k'}^L} = \sigma'(z_{k'}^L) \text{ et } \frac{\partial z_{k'}^L}{\partial \omega_{kk'}^L} = x_k^{L-1}$$

Pour éviter toute confusion nous rappelons que

$$\sigma'(z_{k'}^L) = \frac{\partial \sigma(z_{k'}^L)}{\partial z_{k'}^L}$$

Le résultat de ce calcul s'écrit usuellement :

$$\frac{\partial E}{\partial \omega_{kk'}^L} = x_k^{L-1} \delta_{k'}^L, \text{ avec } \delta_{k'}^L = \sigma'(z_{k'}^L)(x_{k'}^L - t_{k'}^L)$$

En effet il faut sauvegarder $\delta_{k'}^L$ comme terme d'initialisation au calcul itératif qui va suivre et qui se déroule en sens inverse du réseau de neurones.

Rétropropagation itérative

Pour toutes les couches cachées d'indice ℓ il devient possible de rétropropager l'erreur selon :

$$\delta_{k'}^\ell = \sigma'(z_{k'}^\ell) \times \sum_k \omega_{k'k}^{\ell+1} \delta_k^{\ell+1}$$

Ce qui permet de calculer toutes les dérivées partielles selon l'équation :

$$\frac{\partial E}{\partial \omega_{kk'}^\ell} = x_k^{\ell-1} \delta_{k'}^\ell$$

Avec :

$$\begin{cases} \delta_{k'}^L = \sigma'(z_{k'}^L)(x_{k'}^L - t_{k'}^L) & \text{pour la dernière couche, et} \\ \delta_{k'}^\ell = \sigma'(z_{k'}^\ell) \times \sum_k \omega_{k'k}^{\ell+1} \delta_k^{\ell+1} & \text{sinon} \end{cases}$$

Cette opération est réalisée pour un individu. Evidemment, plus le nombre de ces derniers est important plus la correction de poids est significative.

II.3 Séparateurs à Vaste Marge (SVM)

II.3.1 Définitions

- **Fonction de décision et fonction caractéristique**

Dans un espace de dimension p contenant les individus de différentes classes, on cherche une fonction de décision D permettant d'assigner à chaque individu \mathbf{x}_i sa classe y_i . Pour le cas bi-classe $y_i = \pm 1$, la

fonction de décision D est tout simplement le signe d'une fonction caractéristique f (E. 134). La solution est un classifieur linéaire si les classes sont linéairement séparables (E. 135), ou bien sous forme d'une combinaison de noyaux kernels (voir définition ci-dessous) dans le cas contraire.

$$D(\mathbf{x}) = \text{sign}(f(\mathbf{x})) \quad \text{E. 134}$$

$$f(\mathbf{x}) = \langle \boldsymbol{\omega}, \mathbf{x} \rangle + b \quad \text{E. 135}$$

où $\boldsymbol{\omega} \in \mathcal{R}^p$, $b \in \mathcal{R}$ et $\langle \boldsymbol{\omega}, \mathbf{x} \rangle = \boldsymbol{\omega}^T \mathbf{x}$ est un produit scalaire.

▪ Hyperplan

Un hyperplan est défini comme un sous-espace affine de co-dimension 1 (ex. une droite dans un plan ou un plan dans un espace de dimension 3). L'hyperplan associé à la fonction caractéristique f vérifie :

$$H(\boldsymbol{\omega}, b) = \{ \mathbf{x} \in \mathcal{R}^p / \boldsymbol{\omega}^T \mathbf{x} + b = 0 \}$$

▪ Marge géométrique

La marge géométrique d'un individu \mathbf{x}_i de classe y_i par rapport à l'hyperplan H est donnée par :

$$m_i = \frac{|\langle \boldsymbol{\omega}, \mathbf{x}_i \rangle + b|}{\|\boldsymbol{\omega}\|} = \frac{|f(\mathbf{x}_i)|}{\|\boldsymbol{\omega}\|}$$

Il s'agit de la distance entre un individu \mathbf{x}_i de l'hyperplan H .

▪ Marge numérique

La marge numérique de la fonction caractéristique f est donnée par:

$$\boldsymbol{\mu}_{\boldsymbol{\omega}, b} = \min_i |y_i \langle \boldsymbol{\omega}, \mathbf{x}_i \rangle + b|$$

▪ Hyperplan canonique

Un hyperplan est canonique vis-à-vis du nuage d'individus $\{\mathbf{x}_i\}_{i \in [1, n]}$ s'il vérifie :

$$\min_{\mathbf{x}_i} |\langle \boldsymbol{\omega}, \mathbf{x}_i \rangle + b| = 1 \quad \text{E. 136}$$

Ce qui est équivalent à ce que la marge numérique $\boldsymbol{\mu}_{\boldsymbol{\omega}, b}$ de sa fonction caractéristique f soit de 1.

$$\boldsymbol{\mu}_{\boldsymbol{\omega}, b} = 1$$

▪ Vecteurs supports

Les vecteurs supports sont les individus d'apprentissage appartenant à l'ensemble A tel que :

$$A = \{ \mathbf{x}_i \in \mathcal{R}^p / i \in [1, n] \text{ et } |y_i (\boldsymbol{\omega}^T \mathbf{x}_i + b)| = \boldsymbol{\mu}_{\boldsymbol{\omega}, b} \}$$

Pour un hyperplan canonique les vecteurs supports vérifient :

$$A = \{ \mathbf{x}_i \in \mathcal{R}^p / i \in [1, n] \text{ et } |y_i (\boldsymbol{\omega}^T \mathbf{x}_i + b)| = 1 \}$$

▪ Noyau et matrice de Gram associée

Un noyau k est défini comme suivant:

$$k : \mathfrak{R}^p \times \mathfrak{R}^p \rightarrow \mathfrak{R}$$

$$(\mathbf{x}, \mathbf{z}) \mapsto k(\mathbf{x}, \mathbf{z})$$

La matrice de Gram du noyau k est définie par $G \in M(n, n)$ telle que:

$$G_{i,j}^k = k(\mathbf{x}_i, \mathbf{x}_j)$$

▪ Noyau positif

Un noyau est dit positif si sa matrice de Gram est symétrique définie positive.

II.3.2 SVM linéaires

II.3.2.1 Cas séparable bi-classe

La solution recherchée dans les SVM linéaires permet de trouver d'abord un hyperplan linéaire permettant de discriminer les classes. Il s'agit de trouver les paramètres (ω, b) qui définissent la fonction caractéristique f dont le signe permet de prédire de quel côté de l'hyperplan se situe un individu d'apprentissage. Aussi la valeur prise par la fonction caractéristique doit être de même signe que y . En ce sens la solution vérifie :

$$\forall i \in [1, n], y_i f(\mathbf{x}_i) > 0 \quad \text{E. 137}$$

Dans un format canonique, d'après (E. 136 et E. 137), on obtient la contrainte suivante :

$$\forall i \in [1, n], y_i f(\mathbf{x}_i) \geq 1 \quad \text{E. 138}$$

Les SVM fonctionnent également selon le principe qu'il existe une séparatrice optimale parmi plusieurs possibles. Il s'agit de celle qui maximise la marge $M = \min_i(m_i)$ (voir définition en 0) entre l'hyperplan optimal et les individus d'apprentissage. L'hyperplan optimal est alors défini par les paramètres qui maximisent la marge géométrique des individus d'apprentissage conformément à l'équation suivante :

$$(\omega, b)^* = \arg \max_{\omega, b} \{M\}$$

Ce qui correspond à :

$$(\omega^*, b^*) = \arg \max_{\omega, b} \left\{ \frac{1}{\|\omega\|} \min_{x_i} |(\omega^T \mathbf{x}_i + b)| \right\} \quad \text{E. 139}$$

Pour un hyperplan canonique vérifiant par définition $\min_{x_i} |(\omega^T \mathbf{x}_i + b)| = 1$, la distance géométrique des vecteurs supports à l'hyperplan optimal, usuellement appelée marge, est donnée par:

$$M = \frac{1}{\|\omega\|}$$

Il s'agit du paramètre à maximiser dans les SVM.

Au bilan, la solution des SVM dans les cas linéairement séparables consiste à résoudre un problème d'optimisation sous contrainte s'écrivant :

$$\begin{cases} \min_{\omega, b} \|\omega\| \\ \forall i \in [1, n], y_i f(\mathbf{x}_i) \geq 1 \end{cases}$$

Dans ce cas, on parle de marge dure (Hard Margin) car les vecteurs supports ont une marge géométrique fixe $M = \frac{1}{\|\omega\|}$ par rapport à l'hyperplan optimal et tous les individus d'apprentissage sont au-delà des deux hyperplans suivants (Figure 114) :

$$\begin{cases} H^+ = \{\mathbf{x} \in \mathfrak{R}^p / \omega^{*T} \mathbf{x} + b^* = +1\} \\ H^- = \{\mathbf{x} \in \mathfrak{R}^p / \omega^{*T} \mathbf{x} + b^* = -1\} \end{cases}$$

II.3.2.2 Cas non séparable bi-classe

Dans le cas de classes non linéairement séparables, on introduit une variable erreur ξ_i qui vient relâcher la contrainte de E. 138. Cette variable est appelée variable ressort et peut être introduite de la manière suivante :

$$\forall i \in [1, n], \quad y_i f(\mathbf{x}_i) \geq 1 - \xi_i$$

Cette écriture donne une forme plus générale des SVM en termes de séparabilité. Une illustration en est donnée en Figure 114 en considérant la fonction noyau notée K comme une fonction identité $K = Id$ puisque nous traitons du cas linéaire. Aussi, un individu est bien classé tant que $0 \leq \xi_i \leq 1$ et il est mal classé dès lors que $\xi_i > 1$. Il s'agit à nouveau d'un problème d'optimisation sous contrainte s'écrivant:

$$\forall i \in [1, n] \begin{cases} \min_{\omega, b} \|\omega\| \\ y_i f(\mathbf{x}_i) \geq 1 - \xi_i \\ \xi_i \geq 0 \\ \sum_{i=1}^n \xi_i \leq C \end{cases} \quad (1) \Leftrightarrow \quad \forall i \in [1, n] \begin{cases} \min_{\omega, b} \|\omega\| + Co \sum_{i=1}^n \xi_i \\ \xi_i \geq 0 \\ y_i f(\mathbf{x}_i) \geq 1 - \xi_i \end{cases} \quad (2)$$

où C et Co sont deux constantes réelles positives. La formulation (2) est plus couramment adoptée pour la résolution des SVM par méthode des multiplicateurs de Lagrange.

Il est à noter que les paramètres à optimiser sont plus nombreux dans le cas non-séparable puisqu'ils intègrent les variables ressorts. A cet égard, la dernière contrainte de la formulation (1) est appliquée sur la somme des variables ressorts plutôt qu'à toutes les variables une à une. Cela revient à appliquer une contrainte globale sur le nombre d'individus mal classés [128]. En tant que paramètre, la constante Co permet d'ajuster le compromis entre maximisation de la marge et minimisation du nombre d'individus mal classés [128]. Cette solution est appelée marge douce (Soft Margin).

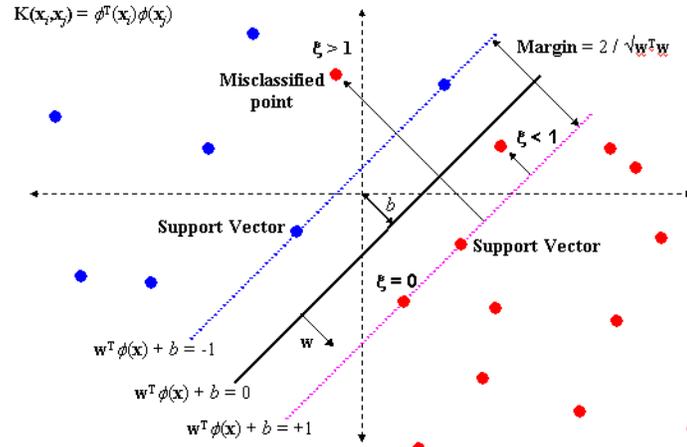


Figure 114 : SVM à marge douce [129]

Sans exposer les détails du calcul d'optimisation quadratique par méthode de Lagrange, il est à retenir que la solution des SVM est obtenue sous la forme suivante :

$$\omega^* = \sum_{i=1}^n y_i \alpha_i^* \mathbf{x}_i$$

$$b^* = y_s - \omega^{*T} \mathbf{x}_s$$

où α_i sont des multiplicateurs de Lagrange. Ils vérifient $\alpha_i > 0$ si \mathbf{x}_i est un vecteur support et $\alpha_i = 0$ sinon. \mathbf{x}_s et y_s sont respectivement les coordonnées et la classe relatives à un vecteur support. Pour rappel $y_s = \pm 1$ selon la classe associée au vecteur support \mathbf{x}_s .

La fonction caractéristique solution s'écrit alors:

$$f(\mathbf{x}) = \sum_{i=1}^n y_i \alpha_i^* \langle \mathbf{x}_i, \mathbf{x} \rangle + b^*$$

II.3.3 SVM non linéaires

L'idée directrice dans les SVM non linéaires consiste à « mapper » les descripteurs initiaux dans un espace $F / \dim(F) > p$ de manière à pouvoir se ramener au cas de la séparabilité linéaire. On peut en effet imaginer qu'en exprimant les individus d'apprentissage dans un espace de dimension supérieure on disperse ces derniers et que l'existence d'une séparatrice linéaire devient plus probable. Le passage est fait au moyen d'une fonction Φ telle que :

$$\begin{aligned} \Phi : \mathcal{R}^p &\rightarrow F \\ \mathbf{x} &\mapsto \Phi(\mathbf{x}) \end{aligned}$$

La fonction caractéristique s'écrit dans ce cas :

$$f(\mathbf{x}) = \omega^T \Phi(\mathbf{x}) + b$$

Puisque les nouveaux descripteurs exprimés dans F sont séparables, la solution s'écrit sous la forme :

$$\omega^* = \sum_{i=1}^p \alpha_i^* y_i \Phi(\mathbf{x}_i)$$

$$f(\mathbf{x}) = \sum_{i=1}^n y_i \alpha_i^* \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}) \rangle_F + b^*$$

où $\langle \cdot, \cdot \rangle_F$ est le produit scalaire dans F .

L'application suivante, qui intervient numériquement dans le calcul de la solution, est un noyau kernel :

$$\begin{aligned} k : \mathfrak{R}^p \times \mathfrak{R}^p &\rightarrow \mathfrak{R} \\ (\mathbf{x}, \mathbf{x}') &\mapsto k(\mathbf{x}, \mathbf{x}') = \langle \Phi(\mathbf{x}), \Phi(\mathbf{x}') \rangle_F \end{aligned}$$

Il s'agit de l'application dont il faut déterminer l'expression analytique pour calculer l'hyperplan linéaire qui permet de séparer les individus dans le nouvel espace des descripteurs. En effet, la méthode des noyaux est adoptée car elle évite notamment le calcul de la transformation des descripteurs dans le nouvel espace. Ainsi il n'est pas nécessaire de définir l'espace d'arrivée F ni l'expression analytique de Φ [128], mais seulement d'exprimer k de manière à respecter certaines propriétés des noyaux et de garantir que F est un espace de Hilbert à noyau reproduisant. La résolution ne fait alors intervenir que des produits scalaires dans le nouvel espace des descripteurs. La solution est directement calculée au moyen de l'expression de k :

$$f(x) = \sum_{i=1}^p \alpha_i^* y_i k(\mathbf{x}_i, \mathbf{x}) + b^*$$