



HAL
open science

Méthodes conjointes de détection et suivi basé-modèle de cibles distribuées par filtrage non-linéaire dans les données lidar à balayage

Benoît Fortin

► **To cite this version:**

Benoît Fortin. Méthodes conjointes de détection et suivi basé-modèle de cibles distribuées par filtrage non-linéaire dans les données lidar à balayage. Automatique. Université du Littoral Côte d'Opale, 2013. Français. NNT : 2013DUNK0359 . tel-01021085

HAL Id: tel-01021085

<https://theses.hal.science/tel-01021085>

Submitted on 9 Jul 2014

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

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

THÈSE

présentée et soutenue publiquement le 22 novembre 2013

pour l'obtention du grade de

Docteur de l'Université du Littoral Côte d'Opale

(Discipline : Automatique, Génie Informatique, Traitement du Signal)

par

Benoît FORTIN



Méthodes conjointes de détection et suivi basé-modèle de cibles distribuées par filtrage non-linéaire dans les données lidar à balayage

Composition du jury

- Président :* **Philippe BONNIFAIT**
Professeur à l'Université de Technologie de Compiègne
- Rapporteurs :* **Roland CHAPUIS**
Professeur à Polytech' Clermont-Ferrand, LASMEA-CNRS
André MONIN
Chargé de Recherche-HDR, LAAS-CNRS, Toulouse
- Examineur :* **Fawzi NASHASHIBI**
Directeur de Recherche, INRIA, Paris
- Directeur de Thèse :* **Jean-Charles NOYER**
Professeur à l'Université du Littoral Côte d'Opale, Calais
- Co-directeur de Thèse :* **Régis LHERBIER**
Maître de Conférences à l'Université du Littoral Côte d'Opale, Calais

*« Il est des hommes que l'épreuve révèle
et auxquels la difficulté sert de tremplin. »*

Marcel Bleustein Blanchet, président de la Fondation de la Vocation

Remerciements

Les travaux présentés dans ce manuscrit ont été effectués au Laboratoire d'Informatique, Signal et Image de la Côte d'Opale (LISIC) de l'Université du Littoral Côte d'Opale (ULCO). Pour cette raison, je tiens à remercier en premier lieu Monsieur Christophe Renaud, Directeur du LISIC et Professeur à l'Université du Littoral Côte d'Opale, de m'avoir accueilli au laboratoire dans les meilleures conditions.

Je remercie chaleureusement mes rapporteurs Monsieur Roland Chapuis, Professeur à Polytech' Clermont-Ferrand et Monsieur André Monin, Chargé de Recherche-HDR au LAAS-CNRS de Toulouse, pour le temps et le soin qu'ils ont pris à lire mon manuscrit ainsi que pour leurs remarques et suggestions pour améliorer celui-ci. Je remercie Monsieur Philippe Bonnifait, Professeur à l'Université de Technologie de Compiègne, pour avoir examiné mon travail et présidé le jury de soutenance, ainsi que Monsieur Fawzi Nashashibi, Directeur de Recherche à l'INRIA Rocquencourt, pour avoir fait partie de mon jury en tant qu'examinateur.

J'adresse mes plus sincères remerciements à mon directeur de thèse Monsieur Jean-Charles Noyer, Professeur à l'Université du Littoral Côte d'Opale, pour avoir dirigé cette thèse ces trois dernières années. Sur le plan scientifique, ses conseils précieux, ses explications, son aide avisée et sa patience m'ont permis de progresser dans beaucoup de domaines et de constamment améliorer ces travaux. Sa confiance et sa sympathie à mon égard ont rendu cette thèse très agréable.

Je tiens à remercier vivement Monsieur Régis Lherbier pour avoir encadré ce travail de thèse avec beaucoup de compétence, d'enthousiasme et de conseils judicieux. Sa disponibilité quotidienne à mon égard ont dépassé largement le cadre professionnel et m'ont permis de me dépasser, aussi bien professionnellement que personnellement. Ces dernières années à ses côtés m'ont permis de trouver un nouveau chemin.

J'adresse mes remerciements à beaucoup de mes collègues du LISIC pour leur sympathie et leur gentillesse. Je tiens dans ce sens à remercier les collègues doctorants avec qui j'ai passé ces dernières années dans le même bureau, avec une ambiance stimulante propice au travail mais aussi à la détente. Je leur souhaite toute la réussite qu'ils méritent dans leur cursus professionnel. J'ai ainsi une pensée particulière pour Guillaume Wacquet, qui m'a permis de rapidement m'imprégner de la vie de doctorant, et pour Georges Stienne, voisin immédiat de bureau, avec qui l'amitié depuis plus de 10 ans a parfois permis de déboucher sur une aide et des conseils précieux de sa part sur le plan professionnel, mais aussi sur des débats passionnés sur les résultats sportifs.

Enfin, je remercie mon cercle d'amis proches, avec qui j'ai pu partager tous ces moments ces dernières années, me permettant d'oublier les nombreuses difficultés rencontrées et de partager les moments heureux, notamment Audrey, pour son aide morale quotidienne qui m'ont permis de me dépasser. Je remercie mes parents, Sylvie et Marc, pour avoir toujours cru en moi ces dernières années malgré un parcours parfois chaotique, ma sœur Stéphanie pour sa présence. Enfin, je terminerai en remerciant ma femme. Quelques mots ne peuvent suffire à exprimer tout ce que je ressens pour elle. Sa patience, sa compassion, son aide psychologique lors des moments très difficiles, mais aussi le bonheur quotidien d'être à ses côtés et son amour profond font que je lui dédie ce travail de thèse et lui dis simplement que je l'aime.

Table des matières

Glossaire	xiii
Abréviations	xv
Introduction générale	xvii
I Détection de véhicules dans les données télémétriques	1
Chapitre 1 - Présentation des capteurs et données	3
1.1 Introduction	3
1.2 Les capteurs lasers	4
1.2.1 Utilisation de la technologie laser	4
1.2.2 La télémétrie laser	4
1.2.3 Capteurs laser de surveillance et détection dans le domaine automobile	6
1.2.3.1 Les capteurs à balayage	6
1.2.3.2 Capteur utilisé pour l'acquisition de données réelles	8
1.3 Les données télémétriques	9
1.3.1 Type de mesures	9
1.3.2 Données réelles	10
1.3.3 Simulateur	10
Chapitre 2 - État de l'art des méthodes de détection	13
2.1 Introduction	13
2.2 Problématique scientifique de la détection	14
2.3 Données télémétriques et représentation	15
2.3.1 Expression des mesures et incertitudes associées	15
2.4 Clustering	17
2.4.1 Clustering non adaptatif	17
2.4.2 Clustering adaptatif	18
2.4.3 Autres méthodes de clustering	20

2.5	Segmentation	20
2.5.1	Minimisation quadratique	21
2.5.2	Extraction de droites en coordonnées cartésiennes	22
2.5.3	Extraction de droites en coordonnées polaires	23
2.5.4	Estimation des imprécisions des paramètres de droites polaires	24
2.5.5	Méthodes de segmentation	24
2.5.5.1	Line Tracking ou Incremental	24
2.5.5.2	Split and Merge (SM)	25
2.5.5.3	Transformée de Hough	27
2.5.5.4	RANSAC	27
2.5.5.5	Autres méthodes	28
2.5.6	Détermination des paramètres des segments	29
2.5.6.1	Extrémités du segment	29
2.5.6.2	Longueur du segment	30
2.5.6.3	Milieu du segment	30
2.6	Modélisation	31
2.6.1	Détection de coins	33
2.6.2	Détermination des paramètres du modèle	34
2.7	Conclusion	35

Chapitre 3 - Détection de segments par propriétés d'invariance géométrique : la méthode SIP **37**

3.1	Introduction	37
3.2	Méthode de détection par invariants géométriques	38
3.2.1	Principe d'appartenance d'impacts distribués à une droite	38
3.2.1.1	Mise en évidence d'un invariant	38
3.2.1.2	Condition d'appartenance généralisée	39
3.2.2	Partitionnement basé modèle (« model based clustering »)	40
3.2.2.1	Notion d'accumulateur	40
3.2.2.2	Construction dans le sens ascendant	41
3.2.2.3	Construction dans le sens descendant	41
3.2.2.4	Construction par dichotomie	42
3.2.2.5	Propriétés	44
3.2.3	Extraction de formes	45
3.2.3.1	Cas idéal : mesures non bruitées	45
3.2.3.2	Extension au cas de mesures bruitées	46
3.2.3.2.1	Rupture de monotonie de la fonction cumulative	46
3.2.3.2.2	Phénomène de recouvrement	47

3.2.3.3	Méthode d'extraction de formes dans des données bruitées et segmentation finale	47
3.2.3.4	Appariement des points orphelins	50
3.3	Extraction des données de la zone d'observation	50
3.4	Évaluation de la méthode de détection SIP	51
3.4.1	Présentation	51
3.4.2	Données synthétiques	52
3.4.2.1	Scénario utilisé	52
3.4.2.2	Critères d'évaluation	52
3.4.2.3	Résultats des évaluations	54
3.4.2.4	Robustesse face au bruit de mesure	56
3.4.3	Données réelles	56
3.4.3.1	Protocole d'étude	56
3.4.3.2	Résultats	58
3.5	Conclusion	59

II Détection et suivi de véhicules dans les données télémétriques 61

Chapitre 4 - Suivi multi-objets : état de l'art 63

4.1	Introduction	63
4.2	Filtrage bayésien	64
4.2.1	Estimation de processus markoviens et notion de modèles	64
4.2.2	Filtrage de Kalman	65
4.3	Méthodes de Monte Carlo séquentielles pour le filtrage non linéaire	66
4.3.1	Approximation des moments d'une densité de probabilité	67
4.3.2	Échantillonnage d'importance	68
4.3.3	Le filtrage particulaire	69
4.3.3.1	Filtrage particulaire SIS	69
4.3.3.2	Filtrage particulaire avec redistribution (SIR)	71
4.3.3.3	Autres méthodes de filtrage particulaire	74
4.3.3.4	Distributions d'importance	74
4.4	Suivi multi-cibles	76
4.4.1	Association de données	77
4.4.1.1	Motivation	77
4.4.1.2	La méthode MHT	78
4.4.1.3	Méthode d'association probabiliste conjointe de données (JPDA)	80
4.4.1.3.1	Présentation	80

4.4.1.3.2	Regroupement de pistes	81
4.4.1.3.3	Probabilité d'association conjointe	82
4.4.1.3.4	Probabilités d'association de données	85
4.4.1.3.5	Implémentation	85
4.4.1.3.6	Discussion	86
4.4.2	L'approche PHD	86
4.4.2.1	Principe	86
4.4.2.2	Filtrage bayésien multi-cibles	87
4.4.2.3	Le filtre PHD (ou fonction intensité)	88
4.4.2.4	Implémentations du filtre PHD	89
4.4.2.5	Évolution du filtre PHD	90
4.5	Conclusion	91

Chapitre 5 - Suivi d'objets multiples dans une architecture classique avec le détecteur

SIP		93
5.1	Introduction	93
5.2	Modèles de mouvement	94
5.2.1	Modèle de dynamique	94
5.2.2	Modèle d'observation	95
5.3	Suivi d'objets avec détection : SIP-SMC-JPDA	96
5.3.1	Cadre théorique	97
5.3.1.1	Initialisation et prédiction	97
5.3.1.2	Construction de la matrice d'association	98
5.3.1.3	Calcul des probabilités d'association conjointes	99
5.3.1.4	Correction de l'état des pistes	100
5.3.1.5	Estimation et rééchantillonnage	100
5.3.2	Gestion de pistes	101
5.3.2.1	Initialisation de pistes	101
5.3.2.2	Arrêt de pistes	103
5.3.3	Expérimentations	104
5.3.3.1	Données synthétiques	104
5.3.3.1.1	Présentation	104
5.3.3.1.2	Critères d'évaluation	105
5.3.3.1.3	Résultats	106
5.3.3.1.4	Robustesse au bruit	110
5.3.3.2	Données réelles	111
5.4	Suivi d'objets avec détection : SIP-SMC-PHD	118
5.4.1	Cadre théorique	118

5.4.1.1	Initialisation	118
5.4.1.2	Prédiction	119
5.4.1.3	Mise à jour	119
5.4.1.4	Phase de rééchantillonnage	120
5.4.1.5	Estimation de l'état des cibles	121
5.4.2	Approche orientée piste	121
5.4.2.1	Placement des particules exploratrices	121
5.4.2.2	Trajectographie	122
5.4.2.3	Arrêt de pistes	123
5.4.3	Vérification de l'étape de séparation des modes (clustering)	124
5.4.4	Expérimentations	127
5.4.4.1	Données synthétiques	127
5.4.4.2	Comparatif des méthodes de suivi JPDA et PHD sur données synthétiques	131
5.4.4.3	Données réelles	132
5.5	Conclusion	135

III Suivi basé-modèle par filtrage non linéaire de cibles distribuées 137

Chapitre 6 - Suivi de cibles multiples distribuées basé sur des propriétés d'invariance géométrique 139

6.1	Introduction	139
6.2	Modélisation du problème	140
6.3	Modèle d'observation et vraisemblance associée	140
6.3.1	Modèle d'observation	140
6.3.2	L'accumulateur comme indicateur de partitionnement	141
6.3.3	La position du pic central comme information de distance capteur-objet	144
6.3.4	Construction de la vraisemblance	146
6.4	Sélection de la zone d'intérêt de l'accumulateur mesuré	147
6.5	Filtre particulaire mis en œuvre	148
6.5.1	Gestion d'objets multiples	148
6.5.2	Architecture	149
6.6	Gestion de pistes	151
6.6.1	Création de pistes	151
6.6.1.1	Instant initial	151
6.6.1.2	Apparition de nouveaux objets	152
6.6.2	Arrêt de pistes	153

6.7	Gestion de l'occultation des objets dans le calcul de la distance capteur-objet. . .	153
6.8	Expérimentations	156
6.8.1	Données synthétiques	156
6.8.1.1	Protocole d'évaluation	156
6.8.1.2	Résultats comparatifs avec les méthodes SIP-SMC-PHD, SM-SMC-PHD et SM-SMC-JPDA	156
6.8.1.3	Robustesse au bruit de mesure	161
6.8.2	Données réelles	161
6.9	Conclusion	166
Chapitre 7 - Suivi de cibles distribuées par approche IP-SMC dans un cadre PHD		169
7.1	Introduction	169
7.2	Résolution du problème de suivi	170
7.2.1	Modèles	170
7.2.2	Architecture du filtre IP-SMC-PHD	171
7.3	Mise en œuvre de la méthode IP-SMC dans le cadre de l'approche PHD	172
7.3.1	Constitution du RFS des observations pour la pondération	172
7.3.2	Exploration de l'espace d'état	173
7.3.3	« Clutter »	174
7.4	Gestion de pistes	174
7.5	Expérimentations	175
7.5.1	Données synthétiques	175
7.5.1.1	Résultats	177
7.5.1.2	Robustesse au bruit	180
7.5.1.3	Comparatif des méthodes IP-SMC et IP-SMC-PHD	181
7.5.2	Données réelles	181
7.5.2.1	Résultats	182
7.5.2.2	Apport de la centrale inertielle	183
7.6	Conclusion	183
Chapitre 8 - Suivi de cibles distribuées : extension au cas multi-lidar		189
8.1	Introduction	189
8.2	Modélisation du mouvement dans une structure de fusion centralisée	190
8.2.1	Transformations de repères locaux	190
8.2.2	Calcul de l'orientation dans chaque repère local	191
8.3	Modélisation globale du problème dans un contexte multi-capteurs	192
8.4	Structure générale de la méthode particulière de suivi multi-lidar	193
8.5	Gestion de pistes	195

8.5.1	Gestion de l'occultation et arrêt de pistes	195
8.5.2	Création de pistes	195
8.6	Résultats expérimentaux	197
8.6.1	Système de perception multi-lidar	197
8.6.2	Configuration routière étudiée et protocole d'évaluation	198
8.6.3	Résultats	198
8.7	Conclusion	201
Conclusion générale et perspectives		203
Annexe A - Calcul des deux premiers moments de l'invariant géométrique A_k		207
Annexe B - Extraction des données observables		209
B.1	Motivation	209
B.2	Données utilisées	210
B.2.1	Repérage du véhicule porteur	210
B.2.2	Données du circuit	210
B.3	Systèmes géodésiques	211
B.4	Extraction des données laser observables	213
B.4.1	Présentation	213
B.4.2	Conversion des impacts télémétriques dans le plan	213
B.4.2.1	Passage des coordonnées géographiques aux coordonnées car- tésiennes	213
B.4.2.2	Passage du système WGS84 au système NTF	214
B.4.2.3	Passage des coordonnées cartésiennes aux coordonnées géo- graphiques	214
B.4.2.4	Passage des coordonnées géographiques aux coordonnées planes	215
B.4.3	Modélisation de la route	215
B.4.4	Conversion des impacts télémétriques dans le plan	216
B.4.5	Résultats et discussions	217
Bibliographie		219

Glossaire

α	: résolution angulaire du télémètre
$\beta^{j,m}$: probabilité d'association entre une piste j et une mesure m
C_k^{th}	: invariant géométrique pour un voisinage de k impacts
CF_t^m	: accumulateur de la scène télémétrique à l'instant t
Δ_t	: période d'échantillonnage du capteur
$D_{t t}$: fonction intensité ou PHD
D_{CF}^j	: distance entre l'accumulateur mesuré et l'accumulateur d'un objet j
D_ρ^j	: distance entre les points milieux des segments d'un objet j et de la mesure
$diag_{veh}$: longueur de la diagonale d'un objet rectangulaire
I_n	: matrice identité de dimension $n \times n$
$long_{veh}$: longueur d'un objet rectangulaire
$larg_{veh}$: largeur d'un objet rectangulaire
λ_c	: paramètre d'une loi de Poisson (pour le clutter)
$\mathcal{N}(m, P)$: loi normale multivariée de moyenne $m \in \mathbb{R}^p$ et de covariance $P \in \mathbb{M}^{p \times p}$ ($p \in \mathbb{N}^*$)
ν	: bruit de mesure sur le paramètre distance d'un point
n	: nombre d'impacts laser issus d'une acquisition par le télémètre
n_s	: nombre de côtés visibles d'un objet
N_{eff}	: nombres de particules efficaces
$\hat{N}_{t t}^T$: nombre estimé de cibles à l'instant t (filtre PHD)
\bar{N}	: nombre de particules moyen associées à une cible (PHD)
N_c	: nombre de télémètres utilisés dans une structure multi-capteurs
N_m	: nombre de particules pour le maillage du sous-espace d'état (initialisation)
N_p	: nombre de particules moyen dans un nuage par cible
N_t	: nombre de particules minimal avant rééchantillonnage
N_Z	: dimension de l'espace d'observation
p_c	: probabilité d'apparition du « clutter »
P_D	: probabilité de détection
P_G	: probabilité d'appartenance à une région de validité (« gate » probability)
p_s	: probabilité de survie d'une cible
P_t	: covariance de l'erreur d'estimation à l'instant t
ρ_d	: distance orthogonale à l'origine d'une droite polaire

ρ_i	: coordonnée polaire de distance d'un point
θ_d	: paramètre angulaire d'une droite polaire
θ_i	: coordonnée angle d'un point
θ_{min}	: limite inférieure du champ d'ouverture angulaire du capteur
θ_{max}	: limite supérieure du champ d'ouverture angulaire du capteur
$\mathcal{U}(n)$: loi uniforme discrète de paramètre $n \in \mathbb{N}^*$
$\mathcal{U}([a, b])$: loi uniforme continue de paramètre $a, b \in \mathbb{R}$
R_t^m	: matrice de covariance de la m -ième mesure à l'instant t
$round$: approximation d'un nombre à l'entier le plus proche
σ_ρ	: incertitude sur la mesure de distance du capteur
σ_{ρ_d}	: incertitude sur le paramètre de distance d'une droite polaire
σ_{θ_d}	: incertitude sur le paramètre angulaire d'une droite polaire
σ_ω	: incertitude sur la mesure de vitesse angulaire de la centrale inertielle
$\omega_t^{j,(i)}$: poids d'importance de la i -ème particule de la j -ième piste à l'instant t
$\tilde{\omega}_t^{j,(i)}$: poids d'importance non-normalisé
\vec{V}_M^R	: vecteur vitesse d'un objet centré en M exprimé dans un repère R
\mathcal{X}_t	: RFS des cibles
X_t	: vecteur d'état à l'instant t (en cas d'unicité)
X_t^j	: vecteur d'état de la j -ième cible à l'instant t
$X_t^{j,(i)}$: vecteur d'état de la i -ième particule de la j -ième cible à l'instant t
$X_{0:t}$: ensemble des états de l'instant initial à l'instant t
$\{X_t\}_{j=1}^J$: ensemble des états des J cibles à l'instant t
$\hat{X}_{t t}$: estimateur de l'état au sens du critère d'estimation choisi à l'instant t
\mathcal{Z}_t	: RFS des observations
Z_t	: vecteur d'observation à l'instant t (en cas d'unicité)
Z_t^ρ	: vecteur d'observation issue de la reconstruction d'une acquisition
Z_t^m	: observation indicée m à l'instant t
$\hat{Z}_t^{j,(i)}$: mesure prédite de la i -ième particule de la j -ième cible
$\{Z_t\}_{m=1}^M$: ensemble des M observations à l'instant t
$Z_{1:t}$: ensemble des observations de l'instant 1 à l'instant t
\hat{Z}_t	: observation prédite à l'instant t

Abréviations

ASIR	: Auxiliary Sampling Importance Resampling
CF	: Cumulative Function
CPHD	: filtre Cardinalized Probability Hypothesis Density
DARPA	: Defense Advanced Research Projects Agency of the United States
DSP	: Digital Signal Processor
ECEF	: repère Earth Centered, Earth Fixed
EKF	: Extended Kalman Filter
ETT-PHD	: Filtre Extented Target Tracking PHD
EM	: Algorithme Expectation-Maximization
ENU	: repère local East, North, Up
FISST	: Finite Set Statistics Theory
GM-PHD	: filtre Gaussian Mixture PHD
IEPF	: Iterative End Point Fit
IP	: Invariant Parameters
IP-SMC	: filtre particulière de suivi sans détecteur
IP-SMC-PHD	: filtre IP-SMC développé dans un cadre PHD
JPDA	: Joint Probabilistic Data Association
JIPDA	: Joint Integrated Probabilistic Data Association
KF	: Kalman Filter
LT	: Line Tracking
LRF	: Laser Rangefinder
MCMC	: Markov Chain Monte Carlo
MHT	: Multiple Hypothesis Tracking
NN	: Nearest Neighbor
NTF	: système géodésique local Nouvelle Triangulation de la France
OSPA	: distance Optimal SubPattern Assignment
OSPA-T	: distance OSPA augmentée avec la notion de piste
PDA	: Probabilistic Data Association
PDBS	: Point-Distance-Based Segmentation
PF	: Particle Filter
PHD	: filtre Probability Hypothesis Density

RANSAC	: RANdom SAmples Consensus
RFS	: Random Finite Set
RGF93	: système géodésique local Réseau Géodésique Français calculé pour l'année 93
RMSE	: Root Mean Squared Error
RPF	: Regularized Particle Filter
RR	: Residual Resampling
SHT	: Standard Hough Transform
SIP	: Segmentation using Invariant Parameters
SIR	: Sampling Importance Resampling
SIS	: Sequential Importance Sampling
SM	: Split and Merge
SMC	: Sequential Monte Carlo
SIP-SMC-JPDA	: filtre JPDA avec détecteur SIP
SM-SMC-JPDA	: filtre JPDA avec détecteur SM
SMC-PHD	: filtre Sequential Monte Carlo PHD
SIP-SMC-PHD	: filtre SMC-PHD avec détecteur SIP
SM-SMC-PHD	: filtre SMC-PHD avec détecteur SM
SR	: Systematic Resampling
SLAM	: Simultaneous Localization And Mapping
SNR	: Signal Noise Ratio
UKF	: Unscented Kalman Filter
TOMHT	: Track-Oriented Multiple Hypothesis Tracking
WGS84	: système géodésique World Geodetic System 1984

Introduction générale

Contexte

Ces travaux de thèse s'intègrent dans le cadre général des systèmes de perception multi-capteurs, plus particulièrement centrés autour d'un télémètre à balayage (Laser Range Finder, LRF). Couplés à d'autres capteurs, ces télémètres ont tout d'abord été utilisés en robotique pour la localisation et la navigation en environnement intérieur notamment. Leurs performances en terme de précision et de fréquence de mesure en particulier, ont permis une utilisation de ces capteurs dans des problématiques de suivi d'objets.

Dans les applications transport, le développement des systèmes d'aide au conducteur (ADAS : Advanced Driver Assistance Systems) fait l'objet de nombreux travaux depuis une vingtaine d'années. Dans notre contexte d'étude, l'objectif est, entre autres, de surveiller l'environnement du véhicule pour informer, à chaque instant, le conducteur de situations potentiellement à risques. Des méthodes de détection et de suivi multi-objets dans des données issues d'un télémètre laser à balayage, embarqué sur un véhicule en mouvement, ont été proposées. Même s'ils conservent quelques limitations inhérentes à la nature physique du signal de mesure, ces capteurs présentent pour les ADAS de nombreux avantages : vision jour/nuit indifférenciée, précision centimétrique, fréquence élevée de mesure, directivité des tirs laser, champ de perception étendu. L'inconvénient majeur d'un télémètre laser mono-nappe est sa sensibilité aux mouvements de tangage, liés à sa directivité : les distances mesurées peuvent être perturbées et donner lieu à des mesures indésirables de la scène, désignées par le terme plus général de « clutter ». Le développement de télémètres multi-nappes, c'est-à-dire travaillant sur plusieurs plans de mesure, a permis de minimiser ces perturbations inhérentes à la nature physique de la mesure.

Bien qu'ayant la particularité de délivrer des informations de positionnement relatives précises contrairement à des capteurs de type caméra vidéo, les télémètres laser se distinguent par la relative pauvreté des informations reçues sur la scène (directement liée à la résolution angulaire du capteur). Ces capteurs sont donc en pratique généralement un élément constitutif d'un système multi-capteurs (GPS, centrale inertielle, caméra, ...). En raison de sa grande ouverture angulaire notamment, une difficulté supplémentaire réside dans la nature multi-cibles de la scène à observer. L'objectif est ici d'assurer conjointement l'estimation dynamique des paramètres de chaque objet tout en proposant une gestion temporelle et spatiale efficace des pistes suivies (apparition, maintien, disparition). Pour finir, la difficulté liée au suivi par ce type de capteur est la nature spatialement distribuée de la cible




FIGURE 1 – Architecture classique de suivi d'objets dans des données télémétriques.

(cible étendue). Pour résoudre ce problème, une solution populaire consiste à procéder à une étape de détection qui permet d'agréger les mesures appartenant à la même cible en délivrant une mesure permettant ainsi de se ramener au cas d'une cible ponctuelle. Dans un esprit différent, des méthodes plus récentes issues de la « communauté radar » consistent à intégrer directement les données brutes au processus de suivi (approche *track-before-detect*).

Pour la première approche, le système de suivi est généralement composé de trois étapes distinctes : une étape de détection, une étape d'association, et une étape de suivi (fig. 1). La détection permet de séparer les mesures qui proviennent d'un même objet et d'en extraire, grâce à une hypothèse de modèle d'objet *a priori*, des paramètres exploitables pour les étapes suivantes. Par l'étape d'association, ces informations sont alors mises en relation avec les objets précédemment suivis puis, dans l'étape de suivi, l'estimation des paramètres des objets permet de reconstituer la scène perçue par le capteur. C'est généralement dans cette dernière étape de suivi que les mécanismes de gestion de pistes apparaissent. Pour les systèmes de suivi basés sur des données télémétriques, des méthodes connues dans la littérature depuis de nombreuses années, mais conçues pour des données radar, ont été adaptées. Il s'agit en particulier de l'approche JPDA (Joint Probabilistic Data Association) [BSF87, AVMS08] ou l'approche MHT (Multiple Hypothesis Tracking) [Bla86]. Celles-ci fournissent un cadre rigoureux de travail qui formalise le calcul des probabilités d'association. Ces approches nécessitent néanmoins des informations fiables provenant du détecteur en amont qui devient un des maillons clés d'une chaîne de suivi de cibles manœuvrantes auquel une attention particulière doit être portée.

L'étape de détection d'objet dans les données LRF est généralement décomposée en trois phases : un clustering, une segmentation et une modélisation. Le clustering cherche à regrouper les mesures appartenant à un même objet, à partir d'un seuil dépendant de la distance inter-impacts, qui est toujours difficile à borner. La segmentation consiste à extraire des primitives qui dépendent de la forme des objets à suivre. Les méthodes couramment rencontrées dans la littérature utilisent un seuil en distance pour obtenir une segmentation robuste et elles proposent de convertir les données polaires en cartésien. La phase de modélisation permet, quant à elle, de fournir des informations à partir d'un modèle de forme d'objet. Lorsque les objets à suivre sont des véhicules, le modèle naturel est le rectangle. Les informations issues de la détection, à savoir les positions et orientations de chaque véhicule dans la scène, sont ensuite intégrées dans une architecture complète de suivi multi-objets. Pour le suivi d'objets et en raison des non-linéarités du modèle d'observation, le problème d'estima-

tion est traité de manière optimale avec les méthodes de Monte Carlo séquentielles (SMC), appelées aussi filtrage particulaire. Présentes depuis le début des années 1990, celles-ci consistent à approximer une densité de probabilité par un nuage de particules et proposent une résolution uniquement limitée par le nombre de particules utilisées. L'efficacité de ces méthodes de suivi avec détections souffre traditionnellement d'inconvénients. La phase d'association reste délicate et la connaissance du nombre de cibles à chaque instant demeure une hypothèse forte. Ces inconvénients peuvent être levés par le développement d'une méthode de suivi basée sur un filtre PHD (Probability Hypothesis Density) [Mah03]. Celui-ci est construit à partir de la théorie RFS (Random Finite Set) en considérant l'ensemble des états et des observations comme deux ensembles de variables aléatoires dont la cardinalité est aussi une variable aléatoire. Il permet notamment de gérer automatiquement les processus de création et d'arrêt de pistes.

Dans cette thèse, on propose une nouvelle méthode de détection basée sur la primitive de type segment. L'étape de segmentation des données télémétriques dans leurs coordonnées naturelles exploite les propriétés d'invariance géométrique de points qui appartiennent à un même segment. Cette approche présente le double avantage de conserver l'optimalité des statistiques du bruit de mesure et d'éviter tout prétraitement par l'utilisation d'un critère d'appartenance indépendant de la distance inter-impacts. Pour le suivi des véhicules, une approche JPDA basée sur les méthodes SMC est tout d'abord proposée. Une seconde méthode conçue autour du filtrage PHD est ensuite développée. Une attention particulière sur la gestion de pistes lors des phases d'initialisation est nécessaire pour ces deux approches mais quelle que soit la méthode de suivi, celle-ci reste néanmoins conditionnée par la qualité du détecteur.

Afin de limiter les problèmes de détection dans ce contexte, des approches *track-before-detect* sont apparues récemment [TL09, VWN12]. Celles-ci n'intègrent pas de processus de détection proprement dit et ne nécessitent pas d'extraction de primitives. Lorsque les données sont distribuées, il est toujours envisageable d'utiliser un modèle de forme déterminé selon le type d'objet à suivre *a priori*. On parle de méthodes basées-modèles [FC07, PT09]. Ce modèle induit une mise en forme des données issues du capteur différente de la détection classique en restant à un niveau d'abstraction moins élevé (proche des impacts). Le modèle choisi est alors projeté dans l'espace d'observation afin d'estimer les paramètres dynamiques de l'objet. Le modèle représentatif de l'objet à suivre est alors directement intégré dans le processus de suivi, et puisque le modèle d'observation est fortement non-linéaire, ce sont encore les méthodes SMC qui sont privilégiées. Pour mettre en œuvre notre approche *track-before-detect*, cette mise en forme du modèle provient du processus d'agrégation des données télémétriques à un même objet inhérente à notre détecteur. Cette méthode de suivi utilise un modèle rectangulaire de véhicules. Chaque objet est alors indépendamment suivi par sa représentation sous la forme d'un partitionnement de points, que l'on désigne sous le nom d'accumulateur. Une association entre l'objet suivi et son accumulateur est alors réalisée grâce au nuage particulaire, nécessitant ainsi de connaître *a priori* le nombre d'objets suivis, et donc des mécanismes de gestion de pistes complémentaires. Finalement, cette méthode est adaptée dans un cadre PHD, qui permet

une gestion automatique des processus de création et de destruction de cibles. Il est ainsi nécessaire de développer des solutions permettant une intégration de la représentation de type accumulateur dans un RFS. Notre méthode se place alors en concurrente directe des méthodes de suivi de cibles étendues par approche ETT-PHD (Extended Target Tracking par PHD) [Mah09, SC12b] ou des méthodes de suivi d'objets *box-particle* [AGB08, SGM⁺12]. De manière plus générale, notre hypothèse de modèle d'objet rectangulaire de dimensions fixes ne doit pas être considérée comme restrictive. Les approches de suivi sans détection développées permettent aisément de s'insérer dans un cadre multi-capteurs, et notamment dans un système de perception composé de plusieurs télémètres (perception multi-lidar).

Organisation de la thèse

En résumé, le manuscrit de thèse est divisé en trois parties distinctes qui abordent les différentes problématiques d'un système de suivi multi-cibles.

La première partie se focalise sur le problème de détection d'objets dans des données télémétriques. Le premier chapitre est consacré à une présentation générale du télémètre et de ses données associées. Le deuxième chapitre est un état de l'art lié à la détection d'objets dans ce type de données, incluant point par point le clustering, la segmentation et la modélisation. Différentes approches existantes sont alors présentées. Le troisième chapitre propose une nouvelle méthode de détection (détecteur SIP) ainsi qu'une évaluation et une comparaison avec certaines approches classiques de détection. Celles-ci sont effectuées sur des données synthétiques et des données réelles.

La deuxième partie traite du problème de suivi d'objets dans une architecture courante détection/association/suivi. Le chapitre 4 présente un état de l'art sur l'estimation dynamique, et notamment sur le filtrage non-linéaire (méthodes de Monte Carlo séquentielles). Les méthodes classiques de suivi multi-cibles avec association y sont également détaillées (JPDA, MHT). Enfin, une généralisation du problème de suivi dans un cadre bayésien multi-cibles est abordée dans le cadre des RFS par le biais du filtrage PHD. Le chapitre 5 regroupe alors les deux approches de suivi développées, à savoir :

- une méthode basée sur le détecteur SIP et sur un filtre JPDA , avec implémentation d'outils spécifiques pour la gestion de pistes ;
- un filtre PHD utilisant également les bénéfices du détecteur SIP , pour lequel des techniques de trajectographie, propres à notre application de suivi de véhicules, sont mises en œuvre.

Pour mettre en valeur la globalité des méthodes proposées (détecteur SIP et suivi), celles-ci sont évaluées et comparées avec les approches de suivi identiques qui diffèrent uniquement par le détecteur, en l'occurrence un algorithme classique Split-and-Merge. Ensuite, les deux méthodes de suivi (JPDA et PHD) alimentées par le détecteur SIP sont comparées entre elles.

La troisième partie présente les méthodes de suivi sans détection que nous avons développées. Le chapitre 6 est une approche basée modèle où les objets sont suivis indépendamment les uns des autres. Le chapitre 7 généralise le même problème dans un cadre PHD.

L'utilisation d'informations supplémentaires issues d'un GPS et d'un système d'information géographique pour définir une région d'observation (route) mais aussi l'utilisation d'informations provenant d'une centrale inertielle pour l'évaluation sur des données réelles nous ont permis de mettre en œuvre un système multi-capteurs, et la fusion de ces différentes informations favorise la fiabilité du système proposé.

Les deux méthodes *track-before-detect* sont alors évaluées et comparées aux méthodes de suivi précédentes, avec détecteur SIP et détecteur Split-and-Merge.

Pour terminer, cette dernière partie met en perspective une approche de suivi multi-lidar, pour lequel le système composée de plusieurs télémètres. L'évaluation de cette méthode de fusion centralisée se fait par comparaison avec la même approche implémentant le suivi dans un cadre mono-capteur (chap. 6). Nous terminerons ce mémoire par une conclusion générale et une perspective de ces travaux.

Première partie

Détection de véhicules dans les données téléométriques

Chapitre 1

Présentation des capteurs et données

1.1 Introduction

L'utilisation et le développement des capteurs de détection occupent une place prépondérante dans tout système de perception et/ou de surveillance de l'environnement. Leur rôle est de prélever une information et de la transmettre sous forme de signal, à des fins de mesure ou de commande. On peut distinguer deux principes de fonctionnement :

- le capteur **actif** qui fonctionne en générateur. Il émet un signal et l'information est déterminée par conversion de l'énergie physique via le signal reçu ;
- le capteur **passif** qui reçoit une énergie sans émettre de signal.

Selon le type d'informations fournies, on parle de :

- capteur **extéroceptif** : il s'agit d'informations sur l'environnement externe au système de perception, au contraire du
- capteur **proprioceptif** qui fournit des mesures sur les paramètres internes du système.

Les capteurs proprioceptifs peuvent être utilisés le plus directement pour la localisation par exemple mais souffrent d'une dérive au cours du temps qui ne permet donc pas de les utiliser seuls. Ce sont par exemple les odomètres, les gyromètres, les accéléromètres, les capteurs d'angle au volant, ... Quelques exemples de capteurs extéroceptifs actifs sont :

- le LIDAR (LIght Detection and Ranging) ou capteur « Laser Scanner » (*Light Amplification by Stimulated Emission of Radiation*) pour déterminer la distance à un objet à l'aide d'un laser ;
- le SONAR (SOund Navigation and Ranging) pour la détection d'objets à l'aide d'ondes sonores ;
- le RADAR (RAdio Detection and Ranging) pour détecter la présence d'objets et déterminer leur distance et vitesse à l'aide d'ondes radio ;

Parmi les capteurs extéroceptifs passifs, on trouve notamment les capteurs optiques de type vidéo caméra, les caméras stéréo, ... Le choix d'un capteur est conditionné par :

- l'objectif ;
- le type d'événement à détecter ;
- la nature de l'événement à détecter : distance, lumière, débit, inertie, sons, pression, ...

- la grandeur physique de l'événement : mesures, temps de réponse, bande passante, ...
- l'environnement : fonctionnement dans l'eau, dans l'air, embarqué, sur support mobile, ...
- le coût.

L'arrivée des capteurs intelligents, *i.e.* des capteurs dans lesquels sont intégrés des composants de calcul et une interface de communication, a apporté des avantages techniques tels que l'amélioration des performances, la communication bidirectionnelle, des fonctions d'étalonnage automatique, d'auto-test, ...

1.2 Les capteurs lasers

1.2.1 Utilisation de la technologie laser

Les applications utilisant la technologie laser se sont développées depuis les années 1970 que ce soit dans le domaine civil ou militaire. On peut par exemple citer son utilisation dans plusieurs champs d'activité :

- l'industrie : découpe, soudage, gravure, ...
- le transfert d'information : lecture, enregistrement, impression, holographie, ...
- le milieu médical : ophtalmologie, dermatologie, dentisterie, ...
- les applications policières : cinémomètre (contrôle de vitesse), criminalistique, ...
- le domaine militaire : armes anti-missile, aide à la visée, ...

Nous nous focalisons dans la suite sur les capteurs télémétriques laser, utilisés dans les domaines de la surveillance et l'automobile.

1.2.2 La télémétrie laser

Le principe de fonctionnement d'un télémètre est d'émettre un rayon laser modulé qui sera réfléchi par la cible (fig. 1.1(a)). La différence de temps entre le moment d'émission et de détection du signal reçu est mesuré (fig. 1.1(b)). Ce temps, appelé temps de vol, sert de calcul à la distance entre le télémètre et la cible ainsi que son incertitude relative $\frac{\Delta D}{D}$:

$$D = \frac{1}{2} \times C \times (T_{Signal_Fin_Mesure} - T_{Signal_Debut_Mesure}) \quad (1.1)$$

$$\frac{\Delta D}{D} = \frac{1}{2} \times \left(\frac{\Delta C}{C} \times \frac{\Delta t}{t} \right) \quad (1.2)$$

où :

- D est la distance entre le capteur et la cible
- C est la célérité de la lumière
- $T_{Signal_Debut_Mesure}$ est le temps de début du signal émis
- $T_{Signal_Fin_Mesure}$ est le temps de fin du signal reçu
- $\frac{\Delta t}{t}$ est l'incertitude relative sur la mesure du temps

- $\frac{\Delta C}{C}$ est l'incertitude relative sur la célérité de la lumière





FIGURE 1.1 – (a) Principe d'un télémètre laser à ligne de tir unique. (b) Détermination du temps de vol par mesure de la distance aller-retour.

La précision de la mesure est donnée par l'écart-type [Bes99] :

$$\sigma_D = \frac{t_{montee_impulsion}}{2.36 \times \text{SNR}} \quad (1.3)$$

où

- $t_{montee_impulsion}$ est le temps de montée de l'impulsion laser ;
- SNR est le rapport signal sur bruit qui dépend en particulier de la distance entre la cible et le télémètre.

Il est à noter que la distance entre le capteur et l'objet peut être déterminée d'autres manières :

- par calcul de l'angle de réflexion avec lequel est reçu le faisceau laser ;
- par calcul du déphasage du signal laser ;
- par modulation du signal émis à une fréquence plus faible que celle de la lumière.

Les caractéristiques importantes de ces capteurs dans le cadre de la surveillance et de la détection sont :

- la précision de la mesure ;

- la portée, *i.e.* la distance maximale pour laquelle le signal émis est effectivement réfléchi ;
- l’ouverture angulaire horizontale et verticale ;
- la sensibilité, *i.e.* la capacité de détection de l’obstacle dans différents environnements climatiques (pluie, brouillard, fumée) ;
- la fiabilité, *i.e.* la capacité de répétitivité de l’information (robustesse au roulis, tangage et lacet).

Ce type de capteur présente néanmoins quelques défauts dont :

- la sensibilité aux propriétés de réflexion des objets ;
- des problèmes dus à la réfraction de la lumière en traversant des objets, des nuages,...

Le télémètre laser est très populaire et utilisé dans de nombreuses applications :

- en sciences géographiques et notamment en topographie [CB08, ZM10] pour la collecte et le traitement de données, le relevé et la retranscription du relief et des bâtiments.
- en études de l’atmosphère et en météorologie : étude des compositions des nuages ou des aérosols [Sug99] ;
- en imagerie : segmentation et classification [WZLS11], reconstruction [AZF11] et modélisation [DPD⁺12].

Dans la suite de ces travaux de thèse, nous utiliserons des capteurs télémétriques dont les spécificités permettent une utilisation dans le domaine du transport. Ces capteurs ont été testés et validés dans la littérature propre à cette application.

1.2.3 Capteurs laser de surveillance et détection dans le domaine automobile

1.2.3.1 Les capteurs à balayage

Dans ce cadre précis où les capteurs sont embarqués sur des véhicules, le télémètre tel qu’il a été décrit précédemment souffre d’inconvénients majeurs : la directivité et l’unicité du tir laser. Dans cette configuration, l’objet suivi ne serait représenté que par un unique signal réfléchi. Cela implique déjà le suivi d’un seul véhicule en cas de réflexion du signal sur cet objet. Dans le cadre de suivi de véhicules routiers, cette situation est impossible à réaliser : le suivi d’un seul véhicule est limité en terme de construction de système de sécurité et d’assistance au conducteur, et ce véhicule n’est en plus pas constamment placé dans la ligne de tir. Celle-ci peut également changer d’inclinaison (tangage ou surcharge arrière du véhicule porteur par exemple).

Pour palier ce phénomène de sortie de l’objet de la ligne de tir, un mouvement de balayage du tir laser dans un même plan horizontal a été ajouté. Ceci a de plus l’avantage d’augmenter la surface de détection des objets par l’obtention de plusieurs impacts réfléchis, mais aussi une perception de l’environnement hors route. Pour contrer les phénomènes de vibrations, un système de miroir rotatif a été introduit afin de réaliser ce balayage de la scène. Le schéma 1.2 montre le fonctionnement d’un capteur à balayage avec ce miroir rotatif permettant d’obtenir plusieurs impacts laser par objet. On parle alors de **cible distribuée** puisque le balayage permet en plus de connaître l’ordre avec lequel les mesures sont acquises. Pour chaque tir laser, une mesure de distance est fournie et permet donc

d'obtenir une vision plus large de l'environnement (section 1.3.2), chaque capteur pouvant le balayer dans un intervalle angulaire défini.




FIGURE 1.2 – Schéma de fonctionnement d'un télémètre laser à balayage équipé d'un miroir rotatif.

Afin de palier le second problème de visée (tirs en direction du sol ou du ciel), un balayage avec un angle d'émission différent peut être mis en place. La robustesse d'acquisition est ainsi renforcée avec l'obtention de plusieurs impacts laser pour chaque échantillonnage d'une rotation du capteur. Ce système permet en outre une vision en 3 dimensions de la scène à surveiller et de récents travaux exploitent ces données [KLW⁺10, WZLS11, SKD⁺12]. Si le capteur effectue uniquement un balayage horizontal, on parlera de capteur monoplan, s'il effectue simultanément un balayage vertical on parlera de capteur multi-couches et s'il effectue ce balayage sur l'ensemble de l'environnement du véhicule-porteur, le terme « omnidirectionnel » est employé. Les figures 1.3 montrent deux types de balayage effectués par les télémètres lorsqu'ils sont embarqués sur un véhicule porteur.




FIGURE 1.3 – (a) Balayage horizontal d'une scène effectué par un télémètre laser embarqué (b) Balayage vertical du même capteur

Les capteurs à balayage sont largement utilisés dans le cadre automobile et visent principalement à améliorer la sécurité dans les transports. On peut citer :

- les systèmes d'assistance au conducteur font désormais partie des outils mis à disposition par les constructeurs en remplissant un panel de tâches de plus en plus large : aide à la trajectoire, franchissement de lignes, freinage d'urgence, changements de directions [IOS12]. Les capteurs sont ainsi montés directement sur le véhicule qui analysera l'environnement.

- Les télémètres peuvent aussi être montés sur des repères fixes (feux de signalisation, rampes, poteaux). Ils sont alors utilisés dans des systèmes de sécurisation de routes notamment aux intersections [CDF07, MRD12]. Ils peuvent aussi de manière analogue servir à la détection et au suivi de piétons [FW01, CZSS07].
- Ces capteurs sont aussi utilisés dans des systèmes conjoints de localisation et de reconstruction d’environnement (SLAM) en collaboration avec d’autres capteurs (caméras, radars) [VAA07, KPL05].
- Des travaux spécifiques à la détection de routes sont aussi réalisés avec ces capteurs [GZLB10, DKF⁺05].
- Dans le cadre des projets de conduite automatisée, le télémètre est un outil indispensable. Ces projets ont pour objectif de réduire les interventions humaines dans les situations de conduites. On peut par exemple citer les projets PROMETHEUS (PROgramme for a European Traffic of Highest Efficiency and Unprecedented Safety) [PRO] qui fut le premier projet conséquent dans le domaine des voitures sans chauffeur, SARTRE (SAfer Road TRains for Environment) [SC12a] pour une conduite en convoi, Google Driverless Car[®] pour une conduite totalement automatisée dans un flux de circulation ou encore Valet Park 4U[®] pour un déplacement autonome d’un véhicule dans une zone de parking. Ces projets sont notamment développés et testés en situations réelles lors de challenges (comme par exemple le Darpa Grand Challenge [DRBU09]).

Des capteurs télémétriques plus spécifiques peuvent être développés :

- un balayage vertical de l’environnement a été introduit avec le capteur IBEO LDML (Ladar Digital Multi Layer) [WF01]. Il s’agit d’un laser qui dispose de 4 plans horizontaux de faisceaux. Ce capteur a été utilisé dans des applications de détections de piétons [FW01, FL03, MRD12], de conduite automatique [EW00], de sécurisation des intersections [Fue05, FW05], d’assistance au changement de voies avec une utilisation conjointe de plusieurs télémètres [FD03] ou encore de construction de plans (« mapping ») [KPL05].
- L’un des inconvénients majeurs du capteur télémétrique est sa sensibilité aux surfaces réfléchies, en particulier par temps pluvieux. Afin de palier ce problème, les séries ALASCA et ALASCA XT des capteurs IBEO LD (Ladar Digital) ont été produites et sont capables de déterminer le type de surface qui a réfléchi le signal (en fonction du pouvoir de réflexion). En fonction de la différence de rayonnement entre le signal réfléchi et l’impulsion émise au niveau du récepteur, le type de surface est alors déterminée par connaissance de la distance entre capteur et cible et de l’angle d’incidence. Ils sont utilisés dans le suivi et la classification d’objets [FD04] et dans la détection de lignes au sol [DKF⁺05].

1.2.3.2 Capteur utilisé pour l’acquisition de données réelles

Les données qui sont utilisées dans cette thèse proviennent d’enregistrements réalisés par l’école des Mines de Paris et la plateforme ^{RT}Maps[®] (Real Time Maps). Ces données seront présentées dans la partie 1.3.2. Ces acquisitions ont été faites avec un capteur IBEO LD et plus spécifiquement

la série IBEO LD A AF (« Automotive Autonomes Fahren »). Ce télémètre (fig. 1.4) a été développé dans le cadre du projet « Autonomes Fahren » [WSGM99, Wil00], dont le but était le développement de véhicules autonomes avec implémentation d'un système d'anti-collision.



FIGURE 1.4 – Télémètre laser IBEO LD A AF

Le capteur IBEO LD A AF est un capteur monoplan équipé d'un processeur de signal numérique (DSP) permettant entre autres le calcul des distances entre ce dernier et l'objet. La précision pour chaque mesure de distance est de 5cm ($\sigma_\rho = 0.05\text{m}$). L'angle d'ouverture est de 360° mais selon la position du capteur, une scène de 90° à 180° peut être balayée. La résolution angulaire peut prendre les valeurs 0.25° , 0.5° ou 1° et la fréquence d'acquisition varie de 10Hz à 40Hz. Il s'agit d'un laser de classe 1 pour la norme de sécurité. La portée est de 250m pour les cibles réfléchissantes et de 40m pour les cibles sombres avec une réflectivité de l'ordre de 5%.

Il est composé de deux interfaces pour le transfert des données :

- le transfert des données brutes en temps réel se fait par bus ARCnet à une unité centrale qui exécute les différents algorithmes de détection, de suivi et de classification d'objets [FDEW02] ;
- la seconde interface délivre des structures de données d'objets par bus CAN.

1.3 Les données télémétriques

1.3.1 Type de mesures

Le télémètre balaye la scène selon une ouverture angulaire définie (section 1.2.3.1). Cela permet, pour chaque tir laser, d'obtenir une mesure de distance. Les données télémétriques consistent donc en l'obtention de n mesures pour un balayage (aussi nommé scan par la suite), où n dépend de l'ouverture angulaire du capteur :

$$n = \frac{\theta_{max} - \theta_{min}}{\alpha} + 1 \quad (1.4)$$

avec :

- θ_{min} et θ_{max} , les limites du champ d'ouverture angulaire et
- α , la résolution angulaire du capteur.

Pour chaque balayage d'angle θ_i ($i \in \llbracket 1, n \rrbracket$), une mesure ρ_i de distance est fournie. Les données sont donc obtenues en **coordonnées polaires**.

1.3.2 Données réelles

Pour les acquisitions utilisées dans cette thèse, un télémètre IBEO LD A AF fait partie d'un ensemble de capteurs présents sur un véhicule. Une plate-forme RTMaps® [Abu05] permet d'enregistrer en temps réel et de synchroniser par une horloge commune les différentes mesures de ces capteurs, à savoir :

- des données délivrées par le télémètre ;
- des données de type image enregistrées par une caméra CCD couleur frontale (non exploitées par les algorithmes en absence de paramètres de calibration) ;
- des données GPS délivrant la position absolue de la voiture dans le référentiel terrestre WGS84 et les vitesses est et nord dans le repère local du télémètre ENU (East-North-Up) (annexe B) ;
- des données issues d'une centrale inertielle délivrant la vitesse angulaire du véhicule porteur.

Le télémètre est monté à l'avant du véhicule porteur avec un angle d'ouverture de 160° ($\theta_{min} = 10^\circ, \theta_{max} = 170^\circ$), une résolution angulaire de 0.25° , une portée maximale 250m et une fréquence d'acquisition de 10Hz.

L'acquisition a été réalisée sur le site d'essai de Versailles Satory et plus particulièrement sur la piste routière (les deux autres pistes étant une piste de vitesse et la piste du Val d'Or). C'est une piste de 3.7km dont les caractéristiques sont proches d'une route nationale et départementale (longue ligne droite, virage avec différents rayons de courbure). La piste empruntée est schématisée sur la figure 1.5.

La figure 1.6 montre un exemple de scène perçue par le télémètre. On peut alors remarquer que certains véhicules sont perçus avec une seule face (véhicule dans l'axe du capteur et de vecteur vitesse colinéaire) et d'autres par deux de ses côtés. On voit également que le nombre d'impacts mesurant les objets dépend de la distance au capteur.

1.3.3 Simulateur

La validation des algorithmes développés ainsi que leur évaluation en terme de précision nécessite de développer un simulateur pour construire différents scénarios de circulation. Cette validation sera ensuite réalisée sur les données réelles.

Il est ainsi possible avec un simulateur de sélectionner des situations remarquables en terme de détection et suivi de véhicules, à savoir :

- l'apparition d'un véhicule dans le champ de vision du capteur télémétrique :
 - un véhicule double le véhicule porteur pour apparaître dans le champ de vision ou il entre dans le champ de vision par l'avant. On parlera alors dans la suite du manuscrit d'**apparition**.
 - Un véhicule apparaît alors qu'il était masqué par un autre objet. On désignera cette situation par **sortie d'occultation**.



FIGURE 1.5 – Plan du circuit (en noir) emprunté pour l’obtention des acquisitions réelles (source Google Maps®)




FIGURE 1.6 – Exemple de données fournies par l’Ecole des Mines de Paris et la plate-forme RTMaps® : scène télémétrique observée représentée dans un repère cartésien

- la disparition d’un véhicule du champ de vision. On peut distinguer également plusieurs situations :

- le véhicule porteur double un véhicule qui disparaît alors du champ de vision. Le terme **disparition** est alors employé.
- Un véhicule devient masqué par un autre objet. On parlera d'**occultation**, pouvant être partielle (une partie de l'objet est visible) ou totale (aucune mesure ne provient de l'objet).




FIGURE 1.7 – Exemples de scènes simulées : (a) un véhicule visible avec deux faces et un véhicule avec une face (entouré) (b) trois véhicules avec une occultation partielle (entouré) (c) trois véhicules avec une apparition (entouré)

Les figures 1.7 montrent différents exemples de scènes simulées. Les différentes situations particulières évoquées précédemment sont mises en évidence.

Il est possible par le simulateur de sélectionner :

- une dynamique différente pour les objets ;
- l'environnement routier (ligne droite, virage, largeur et nombre des voies, ...) ;
- les caractéristiques du capteur.

Un autre avantage du simulateur est de pouvoir moduler les statistiques des bruits de mesure afin d'évaluer la robustesse au bruit des méthodes développées.

Chapitre 2

État de l’art des méthodes de détection

2.1 Introduction

Les travaux proposés dans cette thèse concernent la mise en œuvre de nouvelles méthodes de suivi multi-objets pour des données télémétriques. Dans l’architecture classique d’un système de suivi (fig. 1), l’étape de détection conditionne tout le processus de suivi. Plus la détection est qualitativement bonne, meilleure sera l’estimation dynamique des objets suivis. Le télémètre laser à balayage fournit des mesures distribuées (§1.3) : les objets ne peuvent pas être considérés comme des cibles ponctuelles. En conséquence, deux approches peuvent être différenciées :

- les techniques **métriques** visent à travailler directement avec les impacts laser issus du processus d’acquisition. Ainsi, dans le domaine de la robotique où les capteurs sont identiques, [LM94] établit une correspondance entre 2 scans successifs en recherchant des transformations rigides (rotations, translations) des données LIDAR. [MML06] a le même objectif de correspondance en proposant une nouvelle métrique qui prend en compte les erreurs de rotation et de translation du télémètre. Ces techniques visent à exclure les éventuelles mesures aberrantes (outliers) et à éviter un processus standard de détection. [TFBD01] utilise le filtrage particulière pour faire une approximation du comportement d’un robot sur lequel est monté le télémètre. Ces approches présentent des inconvénients car elles nécessitent des ressources calculatoires proportionnelles à la taille de l’environnement perçu. Dans notre cas, les méthodes sont testées en environnement extérieur routier, la surface visible de l’environnement est très grande comparée aux applications robotiques d’intérieur (pour le capteur IBEO LD A AF, on peut estimer cette surface à $S \approx 2 \cdot 10^5 \text{m}^2$). De plus, les divers mouvements des objets dans l’environnement (apparition de véhicules, murs, arbres, ...) dégradent la répétitivité des informations dans les scans successifs.
- Les techniques **topologiques** sont plus adaptées à ce processus de suivi. Celles-ci consistent à extraire des informations (segments, coins) des données télémétriques avant de les insérer dans le processus de suivi. Ces approches présentent l’avantage de maintenir un faible nombre d’hypothèses à suivre indépendamment du champ de perception du capteur. Elles facilitent ainsi les processus d’association et de suivi.

Pour cette partie de la thèse, nous nous plaçons dans le cadre des techniques topologiques. En effet, il est préférable d'extraire des informations pertinentes correspondants aux objets effectivement suivis et donc de regrouper en sous-ensembles de points les impacts appartenant aux mêmes objets. Les objets en environnement routier peuvent être approximés par des modèles polygonaux (voiture, camion, moto) et le choix de primitives à extraire est donc conditionné par cette hypothèse.

On peut dans cette optique différencier deux approches :

- la première consiste à extraire des modèles de formes géométriques dans leur globalité (rectangles, cercles, ...) également appelés *bounding-boxes* [KR08, ZWY⁺12].
- la deuxième méthode consiste en une extraction d'éléments, appelés primitives. Les segments [PN05, NGM⁺07, DOA⁺11], du fait de leur simplicité de représentation, peuvent être, dans la plupart des environnements, utilisés comme bases pour construire des modèles polygonaux particuliers ou directement intégrés à un processus de suivi [DF90]. D'autres primitives peuvent être extraites et mises en correspondances : des coins [SK08, LO10], des ensembles de points représentatifs du scan [AKLO10] plutôt utilisé en robotique mobile en intérieur en raison de la répétitivité des scans,...

Nous avons privilégié cette seconde approche et notre choix de primitive s'est porté sur le segment qui permet un large panel de modélisations d'objets. De plus, une étude qualitative sur la seule détection des segments peut être menée.

2.2 Problématique scientifique de la détection

La procédure de détection vise à faire le lien entre les données distribuées issues du capteur et des informations utilisables dans un processus de suivi. Nous avons fait le choix d'extraire des primitives de type segments pour ensuite modéliser les objets à suivre par des polygones. Ce choix influence directement tout le processus de suivi multi-objets et le segment représente un compromis satisfaisant entre la généralité des approches et la description haut-niveau des objets. De plus, celui-ci n'est pas aussi perturbé en cas de mesure fortement bruitée. Cette extraction de primitives se justifie dans notre problématique puisque le but est de suivre des objets, et donc d'estimer les paramètres dynamiques. La phase de détection se décompose alors en plusieurs étapes (fig. 2.1), à savoir le clustering, la segmentation et la modélisation, qui aboutissent à des mesures exploitables pour les filtres employés dans le processus de suivi :




FIGURE 2.1 – Architecture classique de détection dans les données télémétriques : clustering des données, obtention des segments, modélisation et mesures utilisables dans un processus de suivi.

1. le **clustering** consiste à regrouper un ensemble de données en sous-ensembles (*clusters*) dont les éléments présentent des caractères communs. Dans le cas des données issues de capteurs

télémétriques, il s'agit de regrouper les impacts qui appartiennent à un même objet. Cette étape consiste donc à trouver les discontinuités entre les données.

2. La **segmentation** des données a pour but, avec notre choix de primitives, d'extraire les modèles de type *segment*. L'utilisation d'un modèle géométrique présente plusieurs avantages :
 - les mouvements des objets suivis qui entraînent un changement de forme influent peu sur leur localisation ;
 - cette phase entraîne une réduction des données et donc un processus de suivi plus efficace et moins gourmand en ressources calculatoires ;
 - une phase de classification des objets peut être déduite de cette étape par connaissance des primitives extraites. Elle consiste à étiqueter les observations selon des classes d'objets définies (la classe voiture, la classe camion, ...). Cette classification est rendue possible en utilisant différents critères : la taille des objets ou le comportement dynamique par exemple.
3. La **modélisation** du véhicule permet de passer du modèle segment extrait au modèle de représentation des objets et ainsi de réduire la dimensionnalité des données. Dans notre cas, ceci permet de représenter les objets avec le modèle rectangle choisi pour les véhicules, selon une taille prédéfinie. Cette étape de modélisation peut éventuellement être conditionnée par l'étape de classification.

Ces trois phases seront détaillées à partir de la section 2.4. Nous regroupons pour l'instant dans ce manuscrit les notions utilisées pour l'extraction de segments.

2.3 Données télémétriques et représentation

2.3.1 Expression des mesures et incertitudes associées

Notons P_i un point d'une acquisition laser et n le nombre d'impacts laser total défini par 1.4. Les coordonnées de ce point peuvent être exprimées dans deux repères (fig. 2.2) :

- le repère du capteur où le point est exprimé en coordonnées polaires : $P_i = (\rho_i, \theta_i)$
- le repère « global » (centré sur le repère du capteur par exemple) (O^{ego}, x, y) : $P_i = (x_i, y_i)$

Le passage d'un repère à l'autre s'effectue par :

$$\begin{cases} x_i = \rho_i \cos \theta_i \\ y_i = \rho_i \sin \theta_i \end{cases} \quad (2.1)$$

Selon les données fournies par les constructeurs, les erreurs de mesures en distance ρ et θ sont modélisées par des lois gaussiennes de moyennes nulles et de variances respectives σ_ρ^2 et σ_θ^2 dans le repère du capteur. Les covariances sont nulles du fait de l'indépendance des variables ρ et θ .

Le passage par le repère monde cartésien implique une approximation des variances et covariances des incertitudes de mesures en conservant l'hypothèse de variables gaussiennes centrées et en négligeant les termes d'ordre supérieur à 2 [PRB03]. Ces incertitudes sont données par :




FIGURE 2.2 – Représentation des impacts laser dans dans les repères capteur et monde (centré sur le télémètre)

$$\begin{cases} \sigma_{x_i}^2 &= \sigma_\rho^2 \cos^2(\theta_i) + \rho_i^2 \sigma_\theta^2 \sin^2(\theta_i) \\ \sigma_{y_i}^2 &= \sigma_\rho^2 \sin^2(\theta_i) + \rho_i^2 \sigma_\theta^2 \cos^2(\theta_i) \\ \sigma_{x_i y_i}^2 &= (\sigma_\rho^2 - \rho_i^2 \sigma_\theta^2) \frac{\sin(2\theta_i)}{2} \\ \sigma_{y_i x_i}^2 &= \sigma_{x_i y_i}^2 \end{cases} \quad (2.2)$$

Comme nous l'avons vu dans la partie 1.3.2, l'incertitude sur la mesure d'angle σ_θ est négligeable et on obtient donc une approximation des écarts-types de la précision de mesure :

$$\begin{cases} \sigma_{x_i} &= \sigma_\rho |\cos(\theta_i)| \\ \sigma_{y_i} &= \sigma_\rho |\sin(\theta_i)| \end{cases} \quad (2.3)$$

Dans ce repère cartésien (O^{ego}, x, y) , les variables x_i et y_i ne sont pas indépendantes contrairement aux variables ρ_i et θ_i exprimées dans le repère du capteur.

Une droite polaire (fig. 2.3) est représentée par ses coordonnées (ρ_d, θ_d) où :

- ρ_d représente la distance orthogonale entre l'origine du repère et la droite ($\rho_d \geq 0$);
- θ_d est l'angle entre l'axe des abscisses et la normale à la droite passant par l'origine. On choisira de travailler dans l'intervalle $]-\pi, \pi]$ pour cet angle.

En coordonnées polaires, un point $P_i = (\rho_i, \theta_i)$ appartient à la droite (D) s'il vérifie :

$$\rho_i \cos(\theta_d - \theta_i) = \rho_d \quad (2.4)$$

La distance du point P_i à la droite (D) , nommée d_h , se calcule par :

$$d_h = |\rho_i \cos(\theta_i - \theta_d) - \rho_d| \quad (2.5)$$




FIGURE 2.3 – Géométrie dans un repère polaire

2.4 Clustering

L'étape de clustering vise à regrouper en sous-ensembles les impacts appartenant à un même objet. En raison d'une absence de connaissances *a priori* sur le nombre de classes à extraire de la scène (le nombre d'objets varie à chaque instant, en plus de l'environnement extérieur à la route), des méthodes de classification non supervisées peuvent être utilisées [JMF99]. Mais ces méthodes ne tiennent pas compte du caractère spécifique des données télémétriques. En effet, les mesures sont distribuées, et deux impacts d'un même objet sont forcément consécutifs. La phase de clustering peut donc se faire par détection des discontinuités en distance entre deux points consécutifs du balayage laser. Ces méthodes de clustering très répandues sont regroupées sous le nom de « Point-Distance-Based Segmentation » (PDBS) [NGM⁺07].

La distance euclidienne D est calculée entre deux impacts successifs par :

$$D(P_i, P_{i+1}) = \sqrt{\rho_{i+1}^2 + \rho_i^2 - 2\rho_{i+1} \rho_i \cos(\alpha)} \quad (2.6)$$

$$D(P_i, P_{i+1}) = \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (2.7)$$

La détection des points de rupture se fait donc en comparant cette distance à une distance seuil D_{th} . Cette méthode permet aussi d'exclure les outliers, par élimination des clusters à faible cardinalité mais ce clustering est conditionné par le choix de D_{th} . On trouve alors, pour ce choix, deux approches dans la littérature :

- le clustering **non adaptatif**. Le seuil D_{th} est invariant quel que soit les impacts du scan.
- le clustering **adaptatif**. D_{th} est fonction de la position des impacts dans le scan.

Ces deux approches sont détaillées dans les paragraphes suivants.

2.4.1 Clustering non adaptatif

Dans notre problématique où les objets à suivre sont des véhicules, il est aisé de définir un seuil fixe à partir de connaissances *a priori*. On peut supposer que deux véhicules sont séparés d'une certaine distance, définissant ainsi la distance seuil D_{th} . Même si le clustering produit des erreurs de classification, cette méthode est très utilisée en raison de sa simplicité [Skr95, CT96, NGM⁺07].

Elle permet en outre d'obtenir un partitionnement des mesures afin de réduire les coûts calculatoires des algorithmes de segmentation lorsque la zone d'observation est étendue.

Cette méthode de clustering souffre d'un inconvénient majeur puisqu'elle ne prend pas en compte la variation de la distance entre deux impacts successifs en fonction de leurs positions spatiales. En effet, cette distance inter-impacts dépend de l'endroit et de l'orientation de la surface visée (fig. 2.4). Il est donc difficile de déterminer une distance D_{th} qui conserve l'optimalité du processus de clustering et d'autres méthodes ont été construites pour palier ce problème.




FIGURE 2.4 – Illustration de l'inconvénient du clustering non adaptatif

2.4.2 Clustering adaptatif

Ce clustering permet d'adapter la distance à chaque itération. Différentes distances ont été proposées dans la littérature et sont récapitulées dans [PN05].

Dietmayer a proposé [DSS01] un seuil D_{th} fonction des distances radiales des impacts :

$$D_{th} = C_0 + C_1 \min \{ \rho_i, \rho_{i+1} \} \quad (2.8)$$

avec $C_1 = \sqrt{2(1 - \cos(\alpha))}$ et C_0 un paramètre lié bruit de mesure en distance des impacts. Ce seuil prend bien en compte la position de la surface visée mais la séparation des clusters reste difficile si les impacts sont trop éloignés.

Un paramètre β a été introduit par [SFS⁺03] dans la détermination du seuil :

$$D_{th} = C_0 + C_1 \frac{\min \{ \rho_i, \rho_{i+1} \}}{\cot(\beta) [\cos(\alpha/2) - \sin(\alpha/2)]} \quad (2.9)$$

où C_0 et C_1 sont identiques à ceux de l'éq. 2.8 et où α est la résolution angulaire. L'angle β prend en compte l'inclinaison de la surface visée (fig. 2.5). Ce seuil permet également de réduire la dépendance très forte qui existe entre le clustering et la distance séparant les objets du capteur.

Un autre critère, introduit par Borges [BA04], prend le point courant P_i comme référence et considère l'orientation admissible de la surface pour agréger l'impact suivant. La distance seuil D_{th} est alors donnée par :

$$D_{th} = C_0 + \rho_i \frac{\sin(\alpha)}{\sin(\lambda - \alpha)} \quad (2.10)$$




FIGURE 2.5 – Représentation schématique d'un scan et des paramètres utilisés pour le critère de Santos (gauche) et Borges (droite)

avec λ (fig. 2.5) cet angle limite de la surface pour lequel le télémètre ne délivrera pas de mesure (surface presque parallèle au tir).

Contrairement aux méthodes précédentes qui bornent la distance inter-impact, [JN11] a déterminé cette distance pour un modèle rectangulaire, comme celui que l'on va utiliser. Elle est fonction de la face visible du modèle, et de l'orientation ψ du véhicule (fig. 2.6). Deux distances sont calculées selon le côté 1 ou 2 du véhicule par :




FIGURE 2.6 – Représentation schématique pour la détermination de la distance inter-impacts pour un modèle rectangulaire

$$d(P_i, P_{i+1}) = \sqrt{r_i^2 \left(1 + \frac{\cos^2(\beta + (i-1)\alpha)}{\cos^2(\beta + i\alpha)} - 2 \frac{\cos(\beta + (i-1)\alpha)}{\cos^2(\beta + i\alpha)} \cos(\alpha) \right)} \text{ pour } \textcircled{1} \quad (2.11)$$

$$d(P_i, P_{i+1}) = \sqrt{r_i^2 \left(1 + \frac{\sin^2(\beta + (i-1)\alpha)}{\sin^2(\beta + i\alpha)} - 2 \frac{\sin(\beta + (i-1)\alpha)}{\sin^2(\beta + i\alpha)} \cos(\alpha) \right)} \text{ pour } \textcircled{2} \quad (2.12)$$

Le paramètre r_i se détermine par :

$$\begin{cases} \text{Si } i = 1 & r_1 = \rho_1 \\ \text{Si } i > 1 & r_i = r_{i-1} \frac{\cos(\beta + (i-2)\alpha)}{\cos(\beta + (i-1)\alpha)} \text{ pour } \textcircled{1} \quad r_i = r_{i-1} \frac{\sin(\beta + (i-2)\alpha)}{\sin(\beta + (i-1)\alpha)} \text{ pour } \textcircled{2} \end{cases} \quad (2.13)$$

Cette méthode semble résoudre le problème de partitionnement assez simplement mais elle oblige à connaître l'orientation des objets, ce qui est un *a priori* trop fort.

2.4.3 Autres méthodes de clustering

Les méthodes précédentes de clustering se basent sur le calcul de la distance inter-impacts avec comparaison à un seuil. Roumeliotis [RB00] propose d'utiliser un filtre de Kalman étendu (EKF) pour modéliser le comportement dynamique de points consécutifs. Une distance statistique de Mahalanobis est alors introduite pour vérifier l'appartenance du point au cluster courant. Cette approche présente le désavantage d'être très sensible aux paramètres d'initialisation et aux bruits de modèle. Un EKF est également rencontré dans [Ada01, ZATX03] mais les points de rupture sont cette fois détectés grâce à une région de validité définie par les impacts laser et adaptée en utilisant une méthode du gradient (méthode ADA). Les distances seuil D_{th} de la section précédente sont réutilisées dans [AKLO10] mais sont combinées avec une mesure de similarité entre les angles.

Des méthodes basées sur le « mean-shift clustering » sont aussi employées [Che95, CM02]. Elles consistent à rechercher les maxima locaux de la densité de probabilité de l'erreur en distance entre l'impact et le segment en utilisant différents noyaux de convolution. [FMCV10] améliore cette méthode par utilisation d'un filtre passe-haut sur l'ensemble des points de rupture potentiels et [BPB12] ajoute la notion de direction dominante des points d'un ensemble de mesures.

Pour des environnements intérieurs très structurés, des approches de Hough ou RANSAC sont utilisées [MCCTM06, NYSJ09].

2.5 Segmentation

L'étape de clustering permet d'obtenir un ensemble de points appartenant à un même objet et la segmentation a donc lieu pour chacun de ces clusters [CT96]. L'objectif de la segmentation est alors d'en extraire les segments. Celle-ci se déroule en deux étapes :

1. une extraction de droites est réalisée sur l'ensemble des points de chaque cluster. Différentes méthodes existent pour déterminer les impacts appartenant à la même droite. Ces méthodes

peuvent être classées en deux catégories : celles qui utilisent des critères de distances (Split and Merge, Line Tracking, IEPF [BA00, NGM⁺07, FMCV10]) et les autres qui n'utilisent pas ce critère de distance (Hough [NYSJ09], Line-Regression [Arr98], RANSAC [BPB12, MCCTM06], Expectation-Maximization [PRB03]). Les paramètres des droites et leurs imprécisions sont alors estimés en minimisant un critère quadratique sur chacun des ensembles de points ainsi déterminés [SKK⁺97, PRB03].

2. Un modèle de la primitive segment est choisi et nécessite la détermination de paramètres supplémentaires et de leurs incertitudes. Il s'agit soit de la combinaison milieu du segment/longueur, soit des deux points extrémités du segment.

Avant de détailler les méthodes d'extraction de droites à partir d'ensembles de points, nous présentons maintenant les outils nécessaires à l'estimation des paramètres de ces droites.

2.5.1 Minimisation quadratique

La minimisation d'un critère quadratique consiste à ajuster un ensemble de données à un modèle mathématique censé décrire ces données, appelée méthodes des moindres carrés (fig. 2.7). Il s'agit donc dans notre application de déterminer le meilleur modèle de droite à partir des impacts laser. La droite retenue sera celle qui rend minimale la somme des carrés des distances des points P_i au modèle estimé.




FIGURE 2.7 – Illustration du problème de minimisation quadratique (dans le cadre de la minimisation des distances des points à la droite)

Pour tenir compte dans le modèle mathématique des erreurs observées, considérons un ensemble d'observations $\mathcal{Y} = \{y_1, y_2, \dots, y_n\}$ comme autant de réalisations d'une variable aléatoire y et $\mathcal{X} = \{x_1, x_2, \dots, x_n\}$ un ensemble de paramètres déterministes. Le bruit de mesure est alors ajouté au modèle pour aboutir à :

$$\mathcal{Y} = f(\mathcal{X}, \kappa) + \epsilon \quad (2.14)$$

où $f(\bullet, \kappa)$ représente le modèle théorique où le paramètre à estimer est κ et ϵ est un bruit blanc gaussien de dimension n de matrice de covariance $\sigma^2 I_n$. Le principe des moindres carrés ordinaires permet d'obtenir à une estimation du paramètre κ en minimisant l'erreur quadratique moyenne :

$$\mathcal{S}(\kappa) = \sum_{i=1}^n (y_i - f(x_i, \kappa))^2 \quad (2.15)$$

La méthode des moindres carrés pondérés introduit une pondération des mesures dans la détermination des paramètres du modèle qui dépend des variances des observations. Le paramètre κ est alors estimé en minimisant l'expression :

$$\mathcal{S}(\kappa) = \sum_{i=1}^n \left(\frac{y_i - f(x_i, \kappa)}{\sigma_i} \right)^2 \quad (2.16)$$

Dans le cas où le modèle n'est plus linéaire, il est possible d'utiliser une approximation linéaire par un développement de Taylor en prenant l'hypothèse de conservation des caractéristiques statistiques des variables (au moins pour les deux premiers moments).

L'estimation de droites par ces méthodes de moindres carrés est fortement biaisée par la présence d'outliers [FB81]. Le clustering apporte dans ce cas, par réjection des outliers, une limitation de ces effets indésirables.

2.5.2 Extraction de droites en coordonnées cartésiennes

De nombreux travaux proposent d'ajuster le modèle en coordonnées cartésiennes [SKK⁺97, BOOCB12]. L'une des raisons principales est la réduction des temps de calculs et la simplicité des calculs associés. Le télémètre fournissant des mesures en coordonnées polaires, la première étape est de transformer ces données et leurs imprécisions en coordonnées cartésiennes (éqs. 2.1 et 2.2).

Nous disposons alors d'un ensemble de points $\mathcal{P} = \{P_i\}, i \in \{1, \dots, n\}$ de coordonnées (x_i, y_i) . L'objectif est donc de trouver la meilleure droite d'équation $y = ax + b$ caractérisant l'ensemble des points (fig. 2.7) au sens du critère quadratique. On définit $\mathcal{X} = \{x_i\}_{1 \leq i \leq n}$ et $\mathcal{Y} = \{y_i\}_{1 \leq i \leq n}$.

La condition déterministe sur \mathcal{X} (§2.5.1) n'est pas remplie. Les coordonnées x_i sont des variables aléatoires de variance dépendante de l'angle θ_i (éq. 2.2). Il s'agit tout d'abord de transférer les erreurs présentes sur les observations x_i sur le bruit ϵ de \mathcal{Y} . Puisque la variance du bruit de mesure n'est pas constante, la méthode des moindres carrés pondérés est indispensable.

La quantité S à minimiser est alors donnée par :

$$\mathcal{S}(a, b) = \sum_{i=1}^n \left(\frac{y_i - (ax_i + b)}{\sigma_i} \right)^2 \quad (2.17)$$

L'estimation des paramètres a et b est donnée par :

$$\begin{cases} \hat{a} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ \hat{b} = \bar{y} - \hat{a}\bar{x} \end{cases} \quad (2.18)$$

avec $\bar{x} = \frac{1}{n} \sum_{i=1}^n (x_i)$ et $\bar{y} = \frac{1}{n} \sum_{i=1}^n (y_i)$.

Les imprécisions associées σ_a^2 et σ_b^2 peuvent aussi être calculées [PRB03, AKLO10].

Si par la suite on souhaite calculer les paramètres $\hat{\rho}_d$ et $\hat{\theta}_d$ de la droite polaire à partir de l'équation 2.19), la transformation inverse est nécessaire. Cependant, le caractère gaussien des paramètres de la droite ou de leurs imprécisions n'est plus assuré.

$$\begin{cases} \hat{a} &= -\frac{1}{\tan(\hat{\theta}_d)} \\ \hat{b} &= \frac{\hat{\rho}_d}{\sin(\hat{\theta}_d)} \end{cases} \quad (2.19)$$

Un travail en coordonnées polaires, sans passage polaire-cartésien-polaire, est donc à privilégier.

2.5.3 Extraction de droites en coordonnées polaires

Il s'agit d'extraire les paramètres (ρ_d, θ_d) d'une droite (éq. 2.4) à partir de n impacts $P_i = (\rho_i, \theta_i)$. Les impacts sont des variables aléatoires gaussiennes indépendantes :

$$\begin{aligned} \forall i, j = 1, \dots, n, \\ \rho_i &\sim N(\bar{\rho}_i, \sigma_{\rho_i}^2) & E\{\rho_i \rho_j\} &= E\{\rho_i\} E\{\rho_j\} \\ \theta_i &\sim N(\bar{\theta}_i, \sigma_{\theta_i}^2) & E\{\theta_i \theta_j\} &= E\{\theta_i\} E\{\theta_j\} \end{aligned}$$

D'après le modèle de droite choisi, la distance orthogonale d_h pour chaque impact P_i (éq. 2.5) représente l'erreur entre P_i et le modèle. Il s'agit donc de minimiser la somme quadratique S de ces erreurs :

$$S = \sum_{i=1}^n d_i^2 = \sum_{i=1}^n (\rho_i \cos(\theta_d - \theta_i) - \rho_d)^2 \quad (2.20)$$

Les paramètres ρ_d et θ_d sont alors obtenus en résolvant le système d'équations non linéaires :

$$\frac{\partial S}{\partial \rho_d} = 0 \text{ et } \frac{\partial S}{\partial \theta_d} = 0 \quad (2.21)$$

Une solution du type moindres carrés ordinaires est suffisante puisque les impacts P_i ont des variances $\sigma_{\rho_i}^2$ égales et des variances $\sigma_{\theta_i}^2$ quasiment nulles. D'après [Arr98], nous obtenons alors :

$$\hat{\theta}_d = \frac{1}{2} \arctan\left(2 \frac{N}{D}\right) \quad (2.22)$$

$$\hat{\rho}_d = \frac{1}{n} \sum_{i=1}^n \rho_i \cos(\theta_i - \theta_d) \quad (2.23)$$

avec

$$N = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n \rho_i \rho_j \sin(\theta_i) \cos(\theta_j) - \sum_{i=1}^n \rho_i^2 \sin(2\theta_i) \quad (2.24)$$

$$D = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n \rho_i \rho_j \cos(\theta_i + \theta_j) - \sum_{i=1}^n \rho_i^2 \cos(2\theta_i) \quad (2.25)$$

$\hat{\theta}_d$ est tout d'abord estimé en s'assurant qu'il vérifie le modèle de droite choisi ($-\pi < \hat{\theta}_d \leq \pi$) et ensuite, $\hat{\rho}_d$ est obtenu par simple moyenne des distances des points à la droite.

2.5.4 Estimation des imprécisions des paramètres de droites polaires

Dans la détermination des imprécisions sur les paramètres des droites polaires, seule l'incertitude σ_{ρ_i} entre en compte puisqu'on néglige l'incertitude σ_{θ_i} . Les erreurs s'expriment par la matrice de covariance [Arr98] :

$$Cov = \begin{pmatrix} \sigma_{\rho_d}^2 & \sigma_{\rho_d\theta_d}^2 \\ \sigma_{\theta_d\rho_d}^2 & \sigma_{\theta_d}^2 \end{pmatrix} \quad (2.26)$$

L'expression des différentes valeurs reprend le terme N et D des équations 2.24 et 2.25 :

$$\sigma_{\rho_d}^2 = \sum_{i=1}^n \left[\frac{1}{n} \cos(\theta_i - \theta_d) + A(\bar{y} \cos \theta_d - \bar{x} \sin \theta_d) \right]^2 \sigma_{\rho_i}^2 \quad (2.27)$$

$$\sigma_{\theta_d}^2 = \frac{\sum_{i=1}^n [N(\bar{x} \cos \theta_i - \bar{y} \sin \theta_i - \rho_i \cos(2\theta_i)) - D(\bar{x} \sin \theta_i + \bar{y} \cos \theta_i - \rho_i \sin(2\theta_i))]^2 \sigma_{\rho_i}^2}{(D^2 + N^2)^2} \quad (2.28)$$

$$\sigma_{\rho_d\theta_d}^2 = \sigma_{\theta_d\rho_d}^2 = \sum_{i=1}^n AB \sigma_{\rho_i}^2 \quad (2.29)$$

avec les termes A et B qui représentent les dérivées partielles, $A = \frac{\partial \theta_d}{\partial \rho_i}$ et $B = \frac{\partial \theta_d}{\partial \theta_i}$:

$$A = \frac{\frac{\partial N}{\partial \rho_i} D - \frac{\partial D}{\partial \rho_i} N}{2(D^2 + N^2)} = \frac{D(\bar{x} \sin \theta_i + \bar{y} \cos \theta_i - \rho_i \sin(2\theta_i)) - N(\bar{x} \cos \theta_i - \bar{y} \sin \theta_i - \rho_i \cos(2\theta_i))}{D^2 + N^2}$$

$$B = \frac{\partial}{\partial \rho_i} \left\{ \frac{1}{n} \sum_{j=1}^n \rho_j \cos(\theta_j - \theta_d) \right\} = \frac{1}{n} \cos(\theta_i - \theta_d) + A(\bar{y} \cos \theta_d - \bar{x} \sin \theta_d)$$

2.5.5 Méthodes de segmentation

Nous présentons ici succinctement les principes de quelques méthodes populaires de segmentation. Il s'agit de trouver l'ensemble des droites décrivant un ensemble \mathcal{P} d'impacts. Le détail de chacune des méthodes et une évaluation comparative sont donnés dans [NGM⁺07, FMCV10].

2.5.5.1 Line Tracking ou Incremental

Il s'agit ici d'une méthode utilisée dans de nombreuses applications [SKK⁺97, BA04]. Elle exploite la distribution des mesures pour déterminer l'ensemble des droites (fig. 2.8). Le principe est basé sur le calcul, par minimisation quadratique, de la droite ajustée à un sous-ensemble de points consécutifs $\{P_i, \dots, P_j\}$. Le point P_{j+1} est ajouté au sous-ensemble si sa distance orthogonale à la droite est inférieure à un seuil d_{seuil} . Les paramètres de la droite sont recalculés. Dans le cas

contraire, une nouvelle droite est estimée à partir des points P_{j+1} et P_{j+2} . L'opération est répétée jusqu'au dernier impact P_n




FIGURE 2.8 – Illustration de la méthode « Incremental » (Line Tracking)

Cet algorithme présente l'avantage de pouvoir être implémenté aisément en ligne puisque les impacts peuvent être ajoutés au fur et à mesure dans l'estimation de la droite courante, sans étape de clustering préalable. L'initialisation d'une nouvelle droite utilise les deux nouveaux points consécutifs. Si l'un des points est un outlier, alors une droite aberrante sera obtenue et l'itération s'arrêtera immédiatement au point suivant, ce qui montre la faible robustesse de la méthode aux outliers entraînant une segmentation excessive de la scène. Une alternative est d'augmenter le nombre de points dans la phase d'initialisation de la droite [NGM⁺07]. Il est aussi possible de mettre en œuvre un clustering préalable non adaptatif mais en perdant le bénéfice d'un traitement séquentiel. Enfin, la distance d_{seuil} est un paramètre délicat à fixer. Si elle est trop élevée, le nombre de droites sera certes réduit mais il y a risque d'associations aberrantes d'impacts. *A contrario*, si elle est trop faible, la segmentation sera là aussi excessive avec un nombre important de droites.

2.5.5.2 Split and Merge (SM)

C'est une méthode populaire fréquemment rencontrée dans la littérature [CT96, SKK⁺97, BA00, NPKJ08]. L'algorithme SM est récursif mais, contrairement à la méthode Incremental, nécessite d'attendre la fin de l'acquisition. Cette méthode se décompose en deux étapes : une phase de division (« Split ») et une phase de fusion (« Merge »).

La première phase consiste à diviser récursivement l'ensemble des points en sous-ensembles par un critère de distance. Cette phase dérive de la méthode Iterative End Point Fit (IEPF) [DH73] qui consiste à construire une droite passant par le premier et le dernier point de l'ensemble. L'impact avec la distance orthogonale maximale à cette droite est alors recherché. Si celle-ci est supérieure à un seuil d_{seuil} , alors l'ensemble est divisé en deux sous-ensembles (fig. 2.9). Puis l'opération est répétée sur chacun de ces sous-ensembles. Le processus s'arrête quand la distance de tous les impacts à la droite est inférieure à d_{seuil} . Pour le calcul des paramètres de la droite pour la méthode Split, tous les points de l'ensemble sont considérés et la droite est ajustée par minimisation quadratique.




FIGURE 2.9 – Illustration de la phase de Split (ici IEPF) de la méthode Split and Merge (SM) (a) 1^{ère} itération : la droite est construite à l'aide des extrémités. Le point P_4 est le plus éloigné et on regroupe donc en deux sous-ensembles. (b) Le processus est répété pour les ensembles $\{P_1, \dots, P_4\}$ et $\{P_4, \dots, P_7\}$

Tout comme la méthode Incremental, la segmentation est conditionnée par le seuil d_{seuil} . De fait, l'algorithme demeure très sensible aux outliers. Une étape de clustering non adaptatif est à privilégier pour ne pas extraire un nombre de droites trop élevé.

La seconde phase de l'algorithme est le Merge, c'est-à-dire une fusion des droites quasi colinéaires issues des sous-ensembles consécutifs [PRB03]. Elle s'opère par un calcul statistique, basé sur le test du Chi-Deux [NGM⁺07]. La distance de Mahalanobis entre deux droites (s_1) et (s_2) de paramètres respectifs $A_1 = (\rho_d^1 \ \theta_d^1)^T$ et $A_2 = (\rho_d^2 \ \theta_d^2)^T$ et de covariances Cov_1 et Cov_2 (éq. 2.26), obtenues lors de la phase de Split, est donnée par :

$$D_{maha} = \sqrt{(A_1 - A_2)^T \times (Cov_1 + Cov_2)^{-1} \times (A_1 - A_2)} \quad (2.30)$$

Si D_{maha} est inférieure à un seuil, alors les droites (s_1) et (s_2) sont fusionnées et les nouveaux paramètres sont calculés par minimisation quadratique en considérant l'ensemble des points appartenant aux droites fusionnées.

Des modifications ont été apportées à cette étape dans le cadre de nos travaux :

- l'intervalle de définition de l'angle θ_d est $]-\pi, \pi]$. Des droites (s_1) et (s_2) presque colinéaires telles que $\theta_d^1 \cong \pi$ et l'autre $\theta_d^2 \cong -\pi$ auront une distance de Mahalanobis ne remplissant pas le test du Chi-Deux. Cette difficulté est levée en calculant une distance de Mahalanobis à 2π .
- La phase de merge décrite ne permet pas de fusionner plus de deux droites dont les impacts proviennent de deux ensembles consécutifs. De manière à augmenter la compacité de la description de la scène, nous avons introduit la possibilité de fusionner plus de deux droites dans l'algorithme.

Il existe bien sûr d'autres méthodes de fusion pour réduire le nombre de droites décrivant un environnement [GBL02, AFG06, AG08], mais aucune d'entre elles ne répond à notre problématique d'obtention de primitive de type segment et l'incertitude associée dans un environnement peu

structuré.

2.5.5.3 Transformée de Hough

La transformée de Hough [Hou59] est un outil très populaire pour l'extraction de primitives (droites, cercles, ellipses,...) dans le domaine de l'image [TLCZ11, BLK12] et en robotique pour l'extraction de droites dans des données télémétriques [PRB03, NYSJ09, BOOCB12]. Son principe se base sur la construction et le remplissage d'une grille (ou accumulateur) dans un espace de paramètres puis sur l'extraction des pics dans cet accumulateur représentant les paramètres les plus probables.

Il est connu qu'il est impossible d'utiliser la représentation cartésienne des droites $y = ax + b$ (discrétisation de l'espace impossible pour a) et que la représentation normale des droites est alors privilégiée [DH71] :

$$\rho_d = x \cos(\theta_d) + y \sin(\theta_d) \quad (2.31)$$

Il existe une infinité de droites passant par un point P_i . Ainsi dans l'espace des paramètres, chaque point est représenté par une courbe. Par analyses successives de chaque point, on obtient alors un ensemble de courbes dont les intersections représentent les paramètres de droites à extraire. Cette opération n'est pas réalisable dans le domaine continu et passe donc par la discrétisation de l'espace des paramètres. L'accumulateur représente alors cet espace discrétisé.

Pour l'étape d'extraction des paramètres de droites les plus représentatifs, il est nécessaire de fixer un nombre minimal de points par droite. Les paramètres des droites demeurent liés à la discrétisation. Afin d'obtenir une meilleure estimation des paramètres et les incertitudes associées, [NGM⁺07] propose de calculer *a posteriori* par minimisation quadratique.

Cette méthode très robuste aux outliers présente quelques inconvénients :

- la zone d'observation est très étendue. Afin d'obtenir une précision suffisante, l'échantillonnage de l'espace des paramètres doit être élevé au détriment du coût calculatoire.
- Un traitement en ligne n'est pas envisageable contrairement à d'autres méthodes, puisque la totalité de l'acquisition est nécessaire lors du remplissage de l'accumulateur.

Une étape de clustering est recommandée pour cet algorithme pour restreindre les zones de recherche dans la construction de l'accumulateur et limiter le risque de création de droites aberrantes (fig. 2.10). Une augmentation du seuil *nb_th* peut atténuer ce phénomène de droites aberrantes mais conduit à une augmentation du taux de non-détection.

2.5.5.4 RANSAC

L'algorithme RANSAC (*RANdom SAmple Consensus*) [FB81] est un algorithme générique d'extraction d'éléments dans un ensemble de données avec un SNR faible. En raison de cette robustesse, de son adaptabilité à de nombreux modèles de primitives et de sa simplicité de mise en œuvre, il est fréquemment implémenté [MNBSV06, BPB12]. Son principe est simple, *i.e.* deux impacts sont




FIGURE 2.10 – Illustration du problème engendré par l'absence de clustering pour la méthode basée sur la transformée de Hough : les impacts cerclés appartiennent à la même droite extraite

aléatoirement choisis parmi l'ensemble de départ. Une droite est ajustée à ces points et on détermine les impacts proches de la droite (appelés inliers) sous la condition d'un seuil. S'il y en a un nombre suffisant nb_th , alors on considère l'ensemble de ces points pour calculer les paramètres de la droite par minimisation quadratique. Ces inliers sont ensuite retirés de l'ensemble et le processus se répète jusqu'à épuisement des données ou jusqu'à un nombre nb_iter maximum d'itérations .

Comme l'algorithme SHT, cette méthode nécessite un clustering afin de ne pas considérer des impacts qui n'ont pas lieu d'être regroupés dans le même sous-ensemble d'inliers (figure 2.10). En effet, cette méthode ne tient pas compte de la répartition des mesures télémétriques. En outre, si la scène est représentée par des clusters à faible cardinalité, le coût calculatoire de cette méthode devient prohibitif, d'autant plus que nb_iter est élevé. Il faut de plus attendre la fin de l'acquisition puisque toutes les données sont nécessaires pour la segmentation, interdisant un traitement en ligne.

2.5.5.5 Autres méthodes

Il existe de nombreuses autres méthodes d'extraction de droites :

- un algorithme de régression linéaire proposé par [Arr98] où le problème d'extraction de lignes est basé sur la transformée de Hough, mais les paramètres sont extraits par des méthodes de clustering par regroupement hiérarchique. Cette méthode utilise une taille de fenêtre glissante influant grandement sur les performances de segmentation et elle est très complexe à implémenter [NGM⁺07].
- L'algorithme *Expectation-Maximization* (EM) est une approche probabiliste utilisée dans des problèmes à variables manquantes en vision par ordinateur [FP03] et en robotique [PRB03]. Son principe est de déterminer par convergence les paramètres d'une droite en deux phases.

La phase Expectation permet de calculer des poids déterminés à partir du modèle de droite pour chaque impact après initialisation aléatoire ; dans la seconde phase Maximization, les paramètres de la droite sont corrigés pour obtenir une convergence des poids des inliers. Les paramètres de la droite sont finalement déterminés si la convergence est atteinte. Bien que très robuste aux outliers, cette méthode ne garantit pas d'obtenir une solution dans le cas où un minimum local est atteint, ce qui entraîne une mauvaise segmentation. De plus, les valeurs initiales conditionnent cette convergence.

- [HS07] exploite la distribution des mesures en introduisant des signaux d'orientation et en les analysant avec des transformées par ondelettes discrètes. Il a cependant montré des résultats un peu inférieurs en terme d'exactitude (taux de fausses alarmes plus élevé et taux de vraies détections plus faible) que le Split and Merge par exemple.
- L'algorithme de Ramer-Douglas-Peucker [NB08] consiste à approcher l'ensemble des impacts par une seule polygone. Cette polygone est ensuite découpée pour extraire les droites.

2.5.6 Détermination des paramètres des segments

La dernière étape de la segmentation consiste à déterminer les paramètres des segments pour chaque droite extraite. Nous connaissons :

- un ensemble de k droites support, représentées par les paramètres $(\hat{\rho}_d^k, \hat{\theta}_d^k)$;
- les imprécisions associées à chaque droite estimée :

$$cov^k = \begin{pmatrix} \sigma_{\rho_d^k}^2 & \sigma_{\rho_d^k \theta_d^k} \\ \sigma_{\theta_d^k \rho_d^k} & \sigma_{\theta_d^k}^2 \end{pmatrix} \quad (2.32)$$

- k ensembles \mathcal{T} d'inliers pour chaque droite.

Pour qu'un segment soit entièrement caractérisé, il faut extraire :

- soit les coordonnées de ses deux extrémités, et les imprécisions associées ;
- soit les coordonnées du point milieu et la longueur, et les imprécisions associées.

Nous avons fait le choix d'une représentation par les coordonnées des extrémités. Cependant, d'autres paramètres nous seront utiles dans la suite :

- l'orientation (déjà connue par l'extraction de droites) et le milieu du segment, pour l'étape de modélisation ;
- la longueur du segment, pour l'évaluation des méthodes de détection.

2.5.6.1 Extrémités du segment

Notons respectivement $P_k^1 = (\rho_k^1, \theta_k^1)$ et $P_k^2 = (\rho_k^2, \theta_k^2)$ le premier et le dernier point d'un ensemble \mathcal{T}_k d'inliers de la droite $s_k = (\hat{\rho}_d^k, \hat{\theta}_d^k)$. Ces points représentent alors les extrémités du segment à extraire, n'appartiennent pas forcément à la droite support. Les extrémités du segment s'obtiennent donc par projection orthogonale des points P_k^1 et P_k^2 et sont notées e_1 et e_2 . Pour $i \in \{1, 2\}$, les

coordonnées sont obtenues par :

$$\begin{cases} \rho_{e_i} &= \sqrt{(\hat{\rho}_d^k)^2 + \rho_k^i \sin(\hat{\theta}_d^k - \theta_k^i)} \\ \theta_{e_i} &= \hat{\theta}_d^k - \arctan \frac{\rho_k^i \sin(\hat{\theta}_d^k - \theta_k^i)}{\hat{\rho}_d^k} \end{cases} \quad (2.33)$$

Le calcul exact des imprécisions sur ces paramètres est complexe puisqu'il fait intervenir celles des droites supports déterminées (section 2.5.3). Nous avons préféré borner ces erreurs et donc de se placer dans le cas le plus défavorable lors de l'utilisation de ces paramètres. La détermination des paramètres des segments autres que ceux de la droite support est postérieure à la phase d'extraction. Cette approximation ne conditionnera donc pas les performances des différents algorithmes étudiés. Les imprécisions pour chaque extrémité e_i sont données, sous l'hypothèse que $\sigma_{\rho_k^i} = \sigma_\rho$ et $\sigma_{\theta_k^i} \cong 0$, par :

$$cov^{e_i} = \begin{pmatrix} \sigma_{\rho_{e_i}}^2 & \sigma_{\rho_{e_i}\theta_{e_i}}^2 \\ \sigma_{\theta_{e_i}\rho_{e_i}}^2 & \sigma_{\theta_{e_i}}^2 \end{pmatrix} = \begin{pmatrix} (\sigma_{\rho_d^k} + \sigma_\rho)^2 & \sigma_{\rho_d^k} \sigma_{\theta_d^k} \\ \sigma_{\theta_d^k} \sigma_{\rho_d^k} & \sigma_{\theta_d^k}^2 \end{pmatrix} \quad (2.34)$$

2.5.6.2 Longueur du segment

La longueur du segment L_k représente la distance euclidienne entre les deux extrémités. Donc, même si le choix de représentation du segment n'inclut pas les extrémités, leur détermination (éq. 2.33) est donc nécessaire pour calculer la longueur du segment. Elle est alors obtenue par :

$$L_k = \sqrt{((\rho_{e_1} \cos(\theta_{e_1}) - \rho_{e_2} \cos(\theta_{e_2}))^2 + ((\rho_{e_1} \sin(\theta_{e_1}) - \rho_{e_2} \sin(\theta_{e_2}))^2)} \quad (2.35)$$

L'imprécision associée sur ce paramètre du segment est aussi bornée, avec :

$$\sigma_{L_k}^2 = (\sigma_{\rho_{e_1}} + \sigma_{\rho_{e_2}})^2 \quad (2.36)$$

2.5.6.3 Milieu du segment

Notons $M = (\rho_M, \theta_M)$ le milieu du segment, au sens géométrique, c'est-à-dire qu'il n'est pas représenté par un impact central de l'ensemble \mathcal{T}_k . Les coordonnées du milieu s'obtiennent à partir des extrémités e_1 et e_2 du segment.

La détermination en coordonnées polaires d'un point milieu n'est pas directe mais s'obtient de manière approchée en considérant que M est le point de tangence de deux cercles de mêmes rayons centrés en e_1 et e_2 .

θ_M s'obtient donc en résolvant l'équation 2.37 par variations successives et en respectant un critère d'arrêt en précision.

$$\frac{\cos(2\theta_M - \theta_{e_1} - \hat{\theta}_d^k)}{\cos(2\theta_M - \theta_{e_2} - \hat{\rho}_d^k)} - \frac{\rho_{e_1}}{\rho_{e_2}} = 0 \quad (2.37)$$

ρ_M se retrouve ensuite puisque M appartient à la droite s_k de paramètres $(\hat{\rho}_d^k, \hat{\theta}_d^k)$. L'inconvénient de ce calcul réside dans une approximation des paramètres (ρ_M, θ_M) obtenus.

Il est donc préférable de calculer les coordonnées cartésiennes (x_M, y_M) puis de les convertir en polaire par :

$$\begin{cases} x_M &= \frac{\rho_{e_1} \cos(\theta_{e_1}) + \rho_{e_2} \cos(\theta_{e_2})}{2} \\ y_M &= \frac{\rho_{e_1} \sin(\theta_{e_1}) + \rho_{e_2} \sin(\theta_{e_2})}{2} \end{cases} \quad (2.38)$$

$$\begin{cases} \rho_M &= \sqrt{x_M^2 + y_M^2} \\ \theta_M &= \arctan \frac{y_M}{x_M} \text{ avec } 0 \leq \theta_M \leq \pi \end{cases} \quad (2.39)$$

Les imprécisions sur les coordonnées du point milieu sont aisément déterminées en utilisant les imprécisions des extrémités du segment précédemment calculées (éq. 2.34). Elles sont bornées par :

$$cov^M = \begin{pmatrix} 4(\sigma_{\rho_d^k} + \sigma_\rho)^2 & 4\sigma_{\rho_d^k}^2 \theta_d^k \\ 4\sigma_{\theta_d^k}^2 \rho_d^k & 4\sigma_{\theta_d^k}^2 \end{pmatrix} \quad (2.40)$$

2.6 Modélisation

À chaque instant d'échantillonnage, on dispose d'un ensemble de segments (et des imprécisions associées) représentant l'environnement perçu par le capteur. Ces ensembles successifs peuvent être utilisés tels quels dans le processus de suivi si l'environnement change très peu d'une acquisition à l'autre, comme cela peut être le cas dans des applications robotiques en intérieur. Une carte de l'environnement est alors construite pour la localisation du robot ou le suivi [AKLO10]. Certains travaux incorporent directement les paramètres des segments dans le processus de suivi. Néanmoins, ces méthodes nécessitent l'apport d'informations supplémentaires : la détection des coins des objets [DF90] ou les distances entre segments et les objets de l'environnement [VR04].

Nos travaux se situent dans le suivi d'objets mobiles, observés par un capteur, lui-même en mouvement et monté sur un véhicule. Le processus de suivi est composé d'une phase d'association entre les paramètres estimés par ce processus à l'instant $(t - 1)$ et les mesures disponibles à l'instant t (les segments). Cette phase d'association est perturbée en cas de changement d'apparence de l'objet suivi ou d'apparition de nouveaux objets, situations courantes dans notre application en raison des mouvements du capteur et des objets. Les paramètres des segments sont très sensibles d'une acquisition à l'autre (la longueur notamment), car ils dépendent de la résolution angulaire du capteur, du mouvement de l'objet dont ils sont issus, et de la dynamique des autres objets.

La figure 2.11 illustre différentes situations :

- une apparition dans le champ de vision du capteur. Veh₁ n'est que partiellement visible et, en fonction de son mouvement relatif, il sera décrit à l'instant suivant par un segment de taille différente voire même par deux segments.

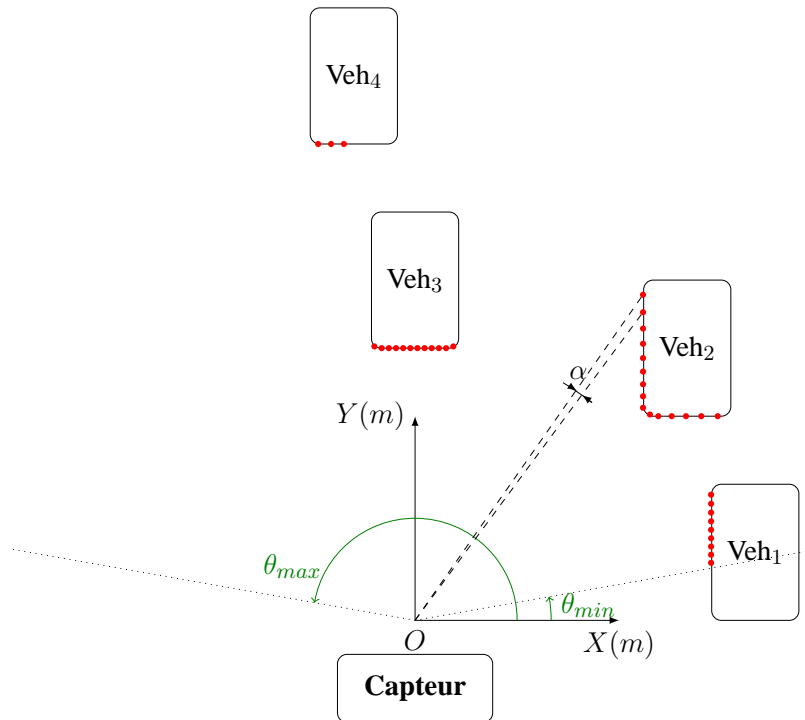


FIGURE 2.11 – Illustration du problème de variabilité des formes des primitives

- Une représentation par une ou deux faces. Le nombre de faces représentant Veh₂ et Veh₃, selon leur mouvement dans la zone d'observation, peuvent varier.
- Une occultation. Le nombre d'impacts pour la perception de Veh₄ peut varier sensiblement en fonction de sa position relative à Veh₃.

La phase d'association est donc rendue plus complexe et la phase de suivi sera perturbée en cas de mauvaise association provoquant des mouvements parasites. Il est donc nécessaire de choisir un modèle d'objet dont les paramètres sont les moins sensibles à ces changements de forme [MM06].

Le modèle de boîte englobante (rectangle) est une bonne représentation des objets et il est souvent utilisé dans des applications de suivi dans les données télémétriques [FC07, ZWY⁺12]. Chaque type de véhicule (voiture, moto, camion, ...) peut être modélisé par un rectangle dont la taille peut varier. Cependant :

- le rectangle est le polygone le plus simple dont la forme est la moins sensible aux changements d'une acquisition à l'autre. Toutefois, il tout à fait envisageable d'utiliser des modèles polygonaux plus complexes après notre étape de segmentation.
- Si plusieurs types de véhicule sont suivis, une phase d'identification préalable à la modélisation est indispensable par type. Cette procédure est difficilement réalisable avec un capteur télémétrique seul et nécessite d'autres informations sur les objets fournies par d'autres capteurs.

La longueur et la largeur étant fixées, le modèle rectangle sera donc entièrement défini par trois paramètres :

- les coordonnées (x_G, y_G) du centre de gravité de l'objet ;

- l'orientation ψ de l'objet, définie comme l'angle minimal entre l'axe horizontal et la droite support de la longueur ($0 \leq \psi < \pi$). Cette orientation donne une information uniquement sur la direction du mouvement de l'objet.

Deux cas peuvent se présenter après l'étape de segmentation (fig. 2.11) :

- un objet est représenté par deux segments (forme « L ») ;
- un objet n'est représenté que par un seul segment (forme « I »).

L'objectif est alors d'ajuster le modèle rectangle choisi à ces données. Certains travaux proposent une modélisation de type rectangle (pour des objets à deux faces de type « L ») en faisant abstraction de l'étape de segmentation. Les impacts sont alors regroupés en clusters sensés représenter un objet et l'objectif est de rechercher un coin parmi l'ensemble des impacts sélectionnés sans contrainte d'orthogonalité pour les deux côtés formant le coin [SFD02] ou avec cette containte [JN11].

La modélisation choisie, s'inspirant de la méthode proposée par [WSKD05], utilise les segments et caractérise les deux formes d'objet. L'ensemble des segments extraits sera divisé en deux classes, à savoir des segments proches et orthogonaux deux à deux qui formeront alors un coin (forme en « L ») et le complément qui seront les support des objets à une seule face visible (forme en « I »).

2.6.1 Détection de coins

Un coin est représenté par l'intersection de deux segment consécutifs, proches et orthogonaux dans notre modèle. Pour déterminer la proximité et l'orthogonalité de deux segments, et prendre en compte les erreurs (orientation et position des segments) , on peut :

- utiliser un seuil fixe pour chacun des tests ;
- utiliser une méthode statistique basée sur un test du Khi-Deux à une dimension liée à l'orientation pour le test d'orthogonalité, et à deux dimensions pour le test de proximité utilisant les extrémités des segments.

Comme pour le calcul du milieu des segments (§2.5.6.3), la détermination des coordonnées d'un coin sera effectuée en coordonnées cartésiennes avant de les transformer en coordonnées polaires.

Notons (x_c, y_c) les coordonnées du coin, intersection de deux segments de droites supports s_1 et s_2 d'équation cartésienne $y = a_1x + b_1$ et $y = a_2x + b_2$. Ces coordonnées cartésiennes, avant le passage en coordonnées polaires (éq. 2.39), sont données par :

$$\begin{cases} x_c = \frac{b_2 - b_1}{a_2 - a_1} \\ y_c = a_1 \frac{b_2 - b_1}{a_2 - a_1} + b_1 \end{cases} \quad (2.41)$$

Les bornes des imprécisions sur le coin (x_c, y_c) sont données par l'équation 2.42, où p_1 (resp. p_2) est l'extrémité du segment issu de s_1 (resp. s_2) la plus proche du coin.

$$cov^c = \begin{pmatrix} \sigma_{\rho_c}^2 & \sigma_{\rho_c \theta_c}^2 \\ \sigma_{\theta_c \rho_c}^2 & \sigma_{\theta_c}^2 \end{pmatrix} = \begin{pmatrix} (\sigma_{\rho_d(p_1)} + \sigma_{\rho_d(p_2)} + 2\sigma_\rho)^2 & (\sigma_{\rho_d \theta_d(p_1)} + \sigma_{\rho_d \theta_d(p_2)})^2 \\ (\sigma_{\theta_d \rho_d(p_1)} + \sigma_{\theta_d \rho_d(p_2)})^2 & (\sigma_{\theta_d(p_1)} + \sigma_{\theta_d(p_2)})^2 \end{pmatrix} \quad (2.42)$$

2.6.2 Détermination des paramètres du modèle

À partir des segments estimés et des éventuels coins détectés, il s'agit d'obtenir un ensemble d'objets modélisés, sous forme de rectangles, dont nous devons déterminer les paramètres.

Pour les objets à deux faces, le centre de gravité du rectangle (x_G, y_G) est obtenu à partir du coin et des dimensions du modèles, où $long_veh$ (resp. $larg_veh$) est la longueur (resp. la largeur) fixée *a priori*. Notons s , de droite support (ρ_d^s, θ_d^s) , le plus grand des deux segments qu'on supposera être la longueur du modèle rectangle et qui définira *de facto* l'orientation ψ de l'objet. Les imprécisions sur le coin sont intégralement reportées sur le centre de gravité. Donc :

$$\begin{cases} \psi = \theta_d^s + \pi/2 \text{ } [\pi] \\ x_G = x_c + \frac{\sqrt{larg_veh^2 + long_veh^2}}{2} \cos(\theta_d^s) \\ y_G = y_c + \frac{\sqrt{larg_veh^2 + long_veh^2}}{2} \sin(\theta_d^s) \end{cases} \quad \text{et} \quad \begin{cases} \sigma_\psi = \sigma_{\theta_d^s} \\ \sigma_{x_G} = \sigma_{x_c} \\ \sigma_{y_G} = \sigma_{y_c} \end{cases} \quad (2.43)$$

Pour les objets à une face, le modèle doit s'appuyer sur un seul segment s . Ce segment sera désigné comme une longueur si sa taille est supérieure $larg_veh$, sinon comme la largeur de ce modèle. Le centre de gravité du rectangle (x_G, y_G) est obtenu à partir des coordonnées du milieu (x_M, y_M) de s et l'orientation ψ à partir de θ_d^s de la droite support. Donc :

si s est une longueur	si s est une largeur	dans les 2 cas
$\begin{cases} \psi = \theta_d^s + \pi/2 \text{ } [\pi] \\ x_G = x_M + \frac{larg_veh}{2} \cos(\theta_d^s) \\ y_G = y_M + \frac{larg_veh}{2} \sin(\theta_d^s) \end{cases}$	$\begin{cases} \psi = \theta_d^s \text{ } [\pi] \\ x_G = x_M + \frac{long_veh}{2} \cos(\theta_d^s) \\ y_G = y_M + \frac{long_veh}{2} \sin(\theta_d^s) \end{cases}$	$\text{et} \quad \begin{cases} \sigma_\psi = \sigma_{\theta_d^s} \\ \sigma_{x_G} = \sigma_{x_c} \\ \sigma_{y_G} = \sigma_{y_c} \end{cases} \quad (2.44)$

Deux exemples de modélisation sont donnés sur la figure 2.12.

2.7 Conclusion

Ce chapitre a présenté l'étape de détection dans les données télémétriques dans le cadre d'un processus global de suivi d'objets. La présentation de la problématique a permis de montrer que la distribution des mesures rend ce processus complexe et nécessite une décomposition en trois étapes que sont le clustering, la segmentation et la modélisation.




FIGURE 2.12 – Exemples de modélisation : (gauche) utilisation d'un coin avec ellipse d'erreur associée à l'estimation du centre de gravité (droite) modélisation avec un seul segment

Le clustering permet de regrouper en sous-ensembles des impacts aux caractéristiques communes, appartenant *a priori* au même objet. Les méthodes de clustering usuelles utilisent des critères de distance pour l'appartenance à un cluster.

La phase de segmentation utilise ces clusters pour construire des ensembles de droites par minimisation quadratique. Les méthodes les plus populaires sont basées soit sur des critères de distance (Split and Merge, Incremental), des approches probabilistes (RANSAC) ou sur des grilles (Hough).

Enfin, la phase de modélisation permet d'ajuster un ensemble de modèles, en l'occurrence des rectangles, à partir de l'ensemble des segments détectés dans la zone d'observation.

Ce processus complet permet donc de passer d'un ensemble de mesures distribuées à un ensemble d'observations qui peuvent être injectées dans la phase de suivi.

Dans le chapitre suivant, nous exposerons une méthode de segmentation concurrente à celles-ci, qui exploite les propriétés d'invariance géométrique des mesures distribuées. La phase de modélisation sera ensuite similaire pour ajuster les rectangles aux segments détectés.

Chapitre 3

Détection de segments par propriétés d'invariance géométrique : la méthode SIP

3.1 Introduction

Le chapitre précédent a permis de présenter l'ensemble du processus de détection dans des mesures distribuées. L'ensemble des méthodes de segmentation populaires utilisées souffrent d'inconvénients majeurs pouvant aboutir à certaines situations indésirables (forte segmentation de l'environnement perçu, non-détections, fausses alarmes) qui se propagent alors dans la phase de modélisation des objets. Ces inconvénients majeurs sont :

- le clustering est appliqué dans la majorité des cas, pour rejeter les outliers et réduire l'espace de recherche. Ce clustering s'appuie sur des méthodes utilisant la distance inter-impacts, quantité qu'il est difficile d'approximer en raison de sa dépendance à la position spatiale des objets et à l'orientation de la surface visée.
- Les méthodes populaires que sont Split-and-Merge et Incremental sont basées sur des critères de distance liés de nouveau à la distance inter-impacts.
- L'approche basée sur la transformée de Hough nécessite une discrétisation de l'espace des paramètres. La qualité d'estimation des paramètres de droites est directement liée à la discrétisation choisie et exige des ressources calculatoires très élevées. La méthode RANSAC souffre aussi d'un problème de temps de calcul en cas de nombre élevé d'impacts. Ces deux méthodes n'exploitent pas en plus le caractère continu des mesures télémétriques dans l'espace de mesure (connaissance de l'ordre d'acquisition).
- Tous ces algorithmes utilisent une approximation de paramètres de droites dans leur processus. Ces estimations sont faites en travaillant dans le repère monde cartésien, approximant alors l'hypothèse gaussienne du bruit de mesure fournie par le constructeur.

Pour palier ces difficultés, une nouvelle méthode de détection de segments a ainsi été développée en utilisant la connaissance sur l'ordre d'acquisition des mesures par le télémètre. Cette méthode, baptisée SIP (Segmentation using Invariant Parameters) [NLF10, FLN12a], vise de plus à remplir certains objectifs :

- la distance inter-impacts ne doit pas être un paramètre dans la conception de la méthode ;
- la méthode, dans son intégralité, doit considérer les mesures issues du capteur en coordonnées naturelles (polaires), sans changement de repère, afin de conserver les statistiques du bruit de mesure ;
- comme toutes les méthodes de détection, l'environnement doit être décrit par un nombre suffisant de segments tout en conservant la précision de la détection et son exactitude (taux de non-détections et de fausses alarmes faibles) ;
- l'approche doit être robuste aux outliers sans engendrer une augmentation du coût calculatoire.

Le chapitre est scindé en deux parties : la première présentera l'ensemble des bases théoriques de la méthode et les algorithmes s'y rapportant. La seconde partie du chapitre consistera en l'évaluation de cette méthode de détection sur des données issues du simulateur et sur des données réelles.

3.2 Méthode de détection par invariants géométriques

3.2.1 Principe d'appartenance d'impacts distribués à une droite

3.2.1.1 Mise en évidence d'un invariant

La base de la méthode SIP réside dans une propriété d'invariance géométrique spécifique aux mesures distribuées, évoquée par [Ale04]. Considérons d'abord la droite de paramètres (ρ_d, θ_d) et un ensemble de points $\{P_i\}$ d'une surface plane présente dans le champ du télémètre (fig. 3.1).




FIGURE 3.1 – Impacts consécutifs réfléchis par une surface plane

Chaque point P_i , de coordonnées (ρ_i, θ_i) , appartenant à la droite vérifie :

$$\rho_d = \rho_i \cos(\theta_d - \theta_i) \quad (3.1)$$

La distribution des mesures implique une relation angulaire entre n'importe quels impacts d'indices i et j donnée par :

$$\theta_j = \theta_i + (j - i)\alpha \quad (3.2)$$

L'idée est de définir un critère d'appartenance de $(2k + 1)$ points consécutifs $\{P_j\}_{j=i-k, \dots, i, \dots, i+k}$ à une même droite (i étant l'indice de l'impact central considéré). On note la fonction cumulative A_k ,

bâtie autour des inverses de mesures de distance dans un voisinage k , définie pour P_i par :

$$A_k(i) = \frac{\sum_{j=i-k}^{j=i+k} \frac{1}{\rho_j}}{\frac{1}{\rho_i}} \quad (3.3)$$

Après simplification, on aboutit à :

$$A_k(i) = \frac{\cos(\theta_d - \theta_i - k\alpha) + \cos(\theta_d - \theta_i - (k-1)\alpha) + \dots + \cos(\theta_d - \theta_i) + \dots + \cos(\theta_d - \theta_i + k\alpha)}{\cos(\theta_d - \theta_i)}$$

On obtient finalement :

$$A_k(i) = 1 + 2 \sum_{j=1}^k \cos(j\alpha) = C_k^{th} \quad (3.4)$$

A_k est donc égal à un invariant géométrique C_k^{th} qui dépend uniquement du voisinage k considéré et de la résolution angulaire du capteur et non de la distance inter-impacts. Cela signifie que $(2k+1)$ points centrés sur le point P_i appartiennent à la même droite si l'équation 3.4 est vérifiée. Cette équation est la base de notre méthode SIP (pour Segmentation using Invariant Parameters).

3.2.1.2 Condition d'appartenance généralisée

Dans la pratique, l'invariant géométrique théorique C_k^{th} ne peut être utilisé tel quel pour tester l'appartenance d'un ensemble de $(2k+1)$ points à une droite. En effet, les mesures ρ_i fournies par le télémètre sont bruitées.

Le bruit de mesure ν_i sur la distance est un bruit blanc gaussien de moyenne nulle et de variance σ_ρ^2 . Les erreurs de mesure sont supposées indépendantes et identiquement distribuées pour chaque impact. Les mesures peuvent s'écrire :

$$\rho_i^m = \rho_i + \nu_i \quad \forall i = \{1, \dots, n\} \quad (3.5)$$

n représente le nombre de points dans le scan ($n = 1 + (\theta_{max} - \theta_{min})/\alpha$). En raison du bruit de mesure, $A_k(i) \neq C_k^{th}$ et l'invariant géométrique théorique doit être recalculé en utilisant les statistiques du bruit.

$A_k(i)$ est une variable aléatoire dont ses deux premiers moments (calcul dans l'annexe A) sont donnés par :

$$E(A_k) = 1 + 2 \sum_{j=1}^k \cos(j\alpha) = C_k^{th} \quad (3.6)$$

$$Var(A_k) \approx (1 - C_k^{th}) \frac{\sigma_\rho^2}{\rho_i^2} \Rightarrow \sigma_{A_k} \approx 2 \frac{\sigma_\rho}{\rho_i} \sum_{j=1}^k \cos(j\alpha) \quad (3.7)$$

Il est donc possible de déduire de l'ensemble des statistiques de la variable aléatoire A_k un test

d'appartenance à une même droite. En utilisant un intervalle de confiance de $3\sigma_{A_k}$, $(2k + 1)$ points successifs d'un scan $\{P_{i-k}, \dots, P_{i+k}\}$ appartiennent à une même droite si :

$$|A_k(i) - C_k^{th}| \leq 3\sigma_{A_k} = 3\frac{\sigma_\rho}{\rho_i}(C_k^{th} - 1) \quad (3.8)$$

L'inégalité 3.8 utilise un seuil qui dépend uniquement de la résolution angulaire α du capteur et du point central P_i du segment. Il n'est de plus pas nécessaire de calculer les paramètres de la droite pour décider de l'appartenance des points à celle-ci, au contraire des méthodes traditionnelles.

Ce critère est le point central de notre méthode de détection. Nous allons montrer qu'elle se décompose en deux étapes analogues aux méthodes de détection usuelles : une première qui peut être considérée comme du partitionnement et une seconde phase de segmentation (extraction des paramètres de chaque segment et détermination des inliers).

3.2.2 Partitionnement basé modèle (« model based clustering »)

3.2.2.1 Notion d'accumulateur

L'inégalité 3.8 définit un critère d'appartenance de $(2k + 1)$ mesures successives à la même droite. Il faut alors utiliser ce critère pour construire une méthode de description de l'environnement perçu. Afin de la garantir la plus compacte possible, le but est de détecter les plus longs segments existants dans la scène.

Ainsi, pour chaque point P_i de la scène, la détection du plus long segment centré en P_i consiste en la recherche du voisinage maximal k . On définit alors une fonction V représentative du voisinage de chaque point P_i qui regroupe l'ensemble des voisinages k pour lesquels le critère 3.8 est vérifié :

$$\begin{cases} V(i, k) = k & \text{ssi le test 3.8 est valide pour le voisinage } k \text{ considéré} \\ = 0 & \text{sinon} \end{cases} \quad (3.9)$$

Le test s'effectue pour $k = \{1, \dots, k_{max}(i)\}$ où $k_{max}(i)$ est le nombre de voisins maximal pour le point P_i :

$$k_{max}(i) = \min(i - 1, n_{max} - i + 1) \quad (3.10)$$

On dérive à partir de la fonction V une fonction CF (pour « Cumulative Function » ou accumulateur) qui représente pour chaque point du scan P_i le nombre maximal de voisins appartenant au segment dont l'impact central est P_i :

$$\forall i \quad CF(i) = \max_k V(i, k) \quad (3.11)$$

CF définit une enveloppe de nombre maximal de voisins pour chaque segment centré sur l'impact P_i . Il s'agit d'une recherche récursive à partir de l'impact central du plus long segment selon le critère 3.8. Si pour un point P_i le critère est vérifié, la fonction CF permet de savoir si l'on peut construire un plus long segment de centre P_{i+1} avec un voisin supplémentaire. La première étape de

notre méthode de détection consiste donc en la construction de l'accumulateur CF avant d'extraire chaque segment de la scène.

3.2.2.2 Construction dans le sens ascendant

La manière la plus intuitive pour trouver le nombre maximal de voisins pour chaque impact P_i est de construire cet accumulateur récursivement et de stopper la construction dès que le test 3.8 n'est plus vérifié. Il s'agit donc d'une recherche dans le sens ascendant puisqu'on incrémente le nombre de voisins possibles pour le point central P_i (dans la mesure où il reste suffisamment d'impacts pour le test). La construction de l'accumulateur CF est résumée dans l'algorithme 1.

```

Entrées : un ensemble  $\mathcal{P} = \{P_1, \dots, P_n\}$  d'impacts
Sorties : l'accumulateur  $CF$  correspondant à la scène
 $CF \leftarrow$  vecteur nul de taille  $n$ ;
pour  $i$  de 1 à  $n$  faire
     $k = 1$ ; // Indicateur du nombre maximal de voisins
     $critere\_arret = FAUX$ ; // Critère sur la validité du test
    tant que  $critere\_arret = FAUX$  faire
        si  $k \leq i - 1$  et  $k \leq n - i$  alors
            si  $|A_k(i) - C_k^{th}| \leq 3 \frac{\sigma_\rho}{\rho_i} (C_k^{th} - 1)$  alors
                 $k++$ ;
            sinon
                 $critere\_arret = VRAI$ ;
            fin
        fin
    fin
     $CF(i) = k - 1$ ; // Stockage
fin

```

Algorithme 1 : Algorithme de construction de l'accumulateur par sens ascendant

Des exemples d'accumulateurs sont donnés sur les figures 3.2 où deux objets rectangulaires sont placés dans l'environnement (les mesures sont ici non bruitées). L'objet rectangulaire 1 présente deux faces visibles en raison de sa position et de son orientation dans l'espace. La figure 3.2(b) montre donc la forme idéale en cas d'absence de bruit de l'accumulateur CF , composé de deux triangles. Les figures 3.2(c) et (d) montrent les mêmes résultats pour un objet avec une seule face visible par le capteur télémétrique. Dès que le test d'appartenance de $(2k + 1)$ points successifs au segment centré en P_i n'est plus vérifié, l'algorithme stoppe la recherche. Dans le cas où l'environnement est peu structuré et les segments petits, la recherche du nombre maximal de voisins s'arrête rapidement et le coût calculatoire est peu élevé.

3.2.2.3 Construction dans le sens descendant

Dans le cas contraire où il existe des segments avec beaucoup d'inliers (éléments à proximité de la route, objets très proches du capteur), le temps de recherche peut s'accroître car on teste tous




FIGURE 3.2 – (a) Objet rectangulaire 1 placé en $(-3, 12)$ et impacts laser non bruités (b) Accumulateur correspondant à l'objet 1 (c) Objet rectangulaire 2 placé en $(-0.5, 12)$ et impacts laser non bruités (d) Accumulateur correspondant à l'objet 2

les nombres de voisins possibles à partir de 1. Une amélioration peut être apportée en effectuant la recherche dans l'autre sens. Le processus (algorithme 2) démarre avec un voisinage égal au nombre maximal d'impacts consécutifs pouvant être testés autour du point central P_i .

Cette méthode de construction permet donc de réduire considérablement le temps nécessaire pour la recherche du voisinage maximal d'un segment centré en P_i dans le cas où un nombre élevé de points appartiennent à un même segment.

3.2.2.4 Construction par dichotomie

Chacune des deux méthodes détaillées ci-dessus apportent un avantage en terme de coût calculatoire selon la taille des segments à détecter. Au cas où ces tailles sont diverses, l'intérêt apportée par la seconde méthode est moindre. Il est ainsi possible d'imaginer travailler avec un processus de recherche par dichotomie, détaillé dans l'algorithme 3.

La table 3.1 montre le nombre de fois où le critère de validité est testé selon la configuration. La valeur nb_vois_max représente la valeur du voisinage maximal à trouver pour un point P_i d'indice 21 sur un total de 50 points laser dans le scan. Si le voisinage maximal est faible, et donc le segment petit, la méthode basique permet de stopper l'algorithme rapidement. Si au contraire le segment est grand, la recherche en descente permet de déterminer plus rapidement ce voisinage maximal. Enfin,

```

Entrées : un ensemble  $\mathcal{P} = \{P_1, \dots, P_n\}$  d'impacts
Sorties : l'accumulateur  $CF$  correspondant à la scène
 $CF \leftarrow$  vecteur nul de taille  $n$ ;
pour  $i$  de 1 à  $n$  faire
     $k = \min(i-1, n-i)$ ; // Indicateur du nombre maximal de voisins
     $critere\_arret = FAUX$ ; // Critère sur la validité du test
    tant que  $critere\_arret = FAUX$  faire
        si  $|A_k(i) - C_k^{th}| \leq 3 \frac{\sigma_\rho}{\rho_i} (C_k^{th} - 1)$  alors
             $critere\_arret = VRAI$ ;
        sinon
             $k--$ ;
        fin
    fin
     $CF(i) = k$ ; // Stockage
fin

```

Algorithme 2 : Algorithme de construction de l'accumulateur par sens descendant

```

Entrées : un ensemble  $\mathcal{P} = \{P_1, \dots, P_n\}$  d'impacts
Sorties : l'accumulateur  $CF$  correspondant à la scène
 $CF \leftarrow$  vecteur nul de taille  $n$ 
pour  $i$  de 1 à  $n$  faire
     $deb = 0$ ; // Borne inférieure de l'espace de recherche
     $fin = \min(i-1, n-i)$ ; // Borne supérieure de l'espace de recherche
    tant que  $fin - deb > 1$ ; faire
         $k = deb + \left\lfloor \frac{fin - deb}{2} \right\rfloor$ ; // Voisinage à tester
        si  $|A_k(i) - C_k^{th}| \leq 3 \frac{\sigma_\rho}{\rho_i} (C_k^{th} - 1)$  alors
             $deb = k$ ;
        sinon
             $fin = k - 1$ ;
        fin
        // Détermination de la borne remplissant le test
        si  $|A_{fin}(i) - C_{fin}^{th}| \leq 3 \frac{\sigma_\rho}{\rho_i} (C_{fin}^{th} - 1)$  alors
             $CF(i) = fin$ ;
        sinon
             $CF(i) = deb$ ;
        fin
    fin
fin

```

Algorithme 3 : Algorithme de construction de l'accumulateur par dichotomie

la méthode par dichotomie permet d'obtenir un compromis satisfaisant du nombre de tests effectués selon le nombre de voisins maximal à déterminer.

On peut en fait calculer le nombre de tests maximal à effectuer selon chacune des méthodes pour un voisinage nb_vois_max donné. Supposons un point d'indice i parmi un ensemble de n_{max}

nb_vois_max	Nb tests selon le sens de parcours		
	Ascendant	Descendant	Dichotomie
3	4	19	6
17	18	4	5
10	11	11	5

TABLE 3.1 – Nombre de calculs du critère d'appartenance à la droite selon différents voisinages maximaux : le test est effectué pour un point d'indice 21 parmi un ensemble de 50 impacts

impacts. Le nombre total de tests N_{tests} à effectuer vaut :

- $N_{tests} = nb_vois_max + 1$ pour la méthode de calcul de l'accumulateur dans le sens ascendant ;
- $N_{tests} = \min(i - 1, n_{max} - i) - nb_vois_max + 1$ pour le parcours descendant ;
- $N_{tests} \leq \frac{\ln(nb_vois_max)}{\ln(2)} + 1$ pour une méthode par dichotomie.

3.2.2.5 Propriétés

Quelle que soit la méthode de construction de l'accumulateur et dans les cas idéaux, la fonction cumulative CF possède les propriétés mathématiques suivantes :

- en raison de l'espace de représentation choisi, il s'agit d'une fonction strictement monotone, respectivement de pentes ± 1 sur les intervalles $[i_{max} - CF(i_{max})]$ et $[i_{max} - CF(i_{max})]$ où i_{max} sont les extrema locaux de la fonction CF ;
- CF est une fonction multimodale dont les extrema locaux représentent la position du milieu du segment (en indice d'impact) et permettent la détermination de la longueur.

La figure 3.2 illustre ces propriétés mathématiques avec la description de la scène par une série de formes triangulaires. Chaque segment est représenté par un triangle dont la largeur de la base est proportionnelle au nombre d'impacts vérifiant l'équation 3.8. Il s'agit donc d'un partitionnement basé modèle, où le modèle choisi est le segment. En effectuant une extraction des triangles de l'accumulateur, on obtient un regroupement des impacts en segments. L'hypothèse fondamentale de notre approche réside donc sur une description possible de la scène sous forme de segments (ce qui est approprié pour notre application). Chaque segment est alors décrit par un triangle dont l'impact central est défini par la position du pic et la valeur CF correspondante vaut $(L - 1)/2$ et permet de calculer la longueur L du segment (longueur en terme de nombre d'impacts).

La première propriété de monotonie peut alors être utilisée pour réduire l'espace de recherche des voisinages maximaux. En effet, les méthodes de construction de l'accumulateur par sens descendant ou par dichotomie utilisent une borne de voisinage maximal selon la position de l'impact P_i dans l'acquisition. La construction de la fonction cumulative CF démarre par exemple avec un voisinage de $\lfloor \frac{n}{2} \rfloor$ points, mais de si longs segments dans la scène sont improbables. On borne donc ce voisinage maximal initial. Si des segments de la scène contiennent un nombre supérieur d'inliers, ils pourront être retrouvés après une phase de regroupement *a posteriori*. Mais la propriété de monotonie permet de garantir la description en longs segments sans cette phase de regroupement.

Supposons que pour un point central P_i , le voisinage maximal τ est validé. À l'impact suivant P_{i+1} , le critère d'appartenance (3.8) est d'abord testé pour le voisinage maximal $\tau' = \tau + 1$, puis on utilise une méthode par dichotomie ou par sens descendant pour déterminer le voisinage maximal si le critère n'est pas rempli pour le voisinage τ' .

3.2.3 Extraction de formes

3.2.3.1 Cas idéal : mesures non bruitées

Ainsi, cette première phase joue le rôle d'un partitionnement de la scène en triangles. L'étape suivante de la méthode consiste donc à extraire les triangles de l'accumulateur CF afin de déterminer l'ensemble des paramètres de chaque segment. La méthode sera tout d'abord explicitée sur des données idéales non bruitées puis adaptée au cas des données télémétriques bruitées.

Des méthodes d'extraction d'éléments existent, notamment les méthodes basées sur la transformée de Hough. De telles méthodes ne seraient pas ici adaptées en raison de l'espace des paramètres spécifique que nous avons créé. En effet, les triangles à extraire sont isocèles. L'indice i_{max} du sommet dont la valeur par la fonction CF est non nulle représente le point central du segment, et la valeur $CF(i_{max})$ représente $(L - 1)/2$ où L est la longueur du segment en nombre d'impacts. L'extraction des triangles se résume donc en une extraction des indices des extrema locaux (pics) de l'accumulateur.

```

Entrées : un ensemble  $\mathcal{P} = \{P_1, \dots, P_{n_{max}}\}$  d'impacts
            l'accumulateur  $CF$  correspondant à la scène
Sorties : un ensemble  $\mathcal{S}$  de segments définies par longueur et point central
            un ensemble  $\mathcal{T}$  d'inliers de chaque segment
 $l = 0$ ; // Indicateur du nombre de segments
tant que  $\exists i / CF(i) \neq 0, \forall i = \{1, \dots, n_{max}\}$  faire
     $i_{max} = \arg \max_i CF(i)$ 
     $seg\_longueur(l) = 2 * CF(i_{max}) + 1$ ; // Longueur du segment
     $seg\_milieu(l) = i_{max}$ ; // Indice du point milieu
    pour  $j = -i_{max} - CF(i_{max}), -i_{max} - CF(i_{max}) + 1, \dots, i_{max} + CF(i_{max})$  faire
         $CF(j) = 0$ ; // Le segment (triangle) a été détecté
    fin
     $\mathcal{T} = \mathcal{T} \cup \{P_{i_{max}-CF(i_{max})}, \dots, P_{i_{max}+CF(i_{max})}\}$ 
     $l_{++}$ 
fin

```

Algorithme 4 : Détection de pics

La procédure proposée utilise les propriétés mathématiques évoquées dans la section précédente et est résumée dans l'algorithme 4. Différents paramètres peuvent alors être calculés en sortie de l'algorithme : longueur du segment, extrémités, paramètres polaires de la droite,...

3.2.3.2 Extension au cas de mesures bruitées

En théorie chaque segment de la scène peut être extrait en utilisant la procédure décrite dans l'algorithme 4. Mais celle-ci doit être modifiée pour tenir compte du bruit présent en pratique dans les impacts laser. La fonction cumulative présente dans ce cas deux perturbations majeures.

3.2.3.2.1 Rupture de monotonie de la fonction cumulative

En présence de bruit, un sous-ensemble d'impacts peut ne plus appartenir au même segment car le test 3.8 n'est plus vérifié. Cela induit alors une perte de monotonie de la fonction CF et peut donc amener à la non-détection de l'élément à longueur maximale. Dans le cas d'outliers (points aberrants), CF peut être nulle dans l'enveloppe d'un triangle. Le test 3.8 n'est pas vérifié même pour les faibles voisinages, comme le montre la figure 3.3 (éléments notés \emptyset). La difficulté est alors de détecter le segment le plus long puisque la propriété de monotonie ne peut plus être utilisée en raison de la discontinuité de la fonction cumulative. La procédure adaptée de détection devra donc prendre en considération ce type de problème.




FIGURE 3.3 – (a) Mesures bruitées associées à un véhicule placé approximativement en $(-4, 2)$ (b) Accumulateur calculé selon la méthode dans le sens ascendant (c) Accumulateur construit dans le sens descendant

La figure 3.3(a) est un exemple de mesures provenant d'une acquisition réelle. Il apparaît clairement que quelques points ne peuvent être agrégés à la même droite. La présence d'impacts manquants et d'outliers perturbent la monotonie de l'accumulateur (figure 3.3(b)). L'extraction des triangles les plus grands est alors compromise en raison de la valeur très faible de CF pour certains indices. La figure 3.3(c) illustre ici l'intérêt de travailler dans le sens descendant : la valeur de CF correspondante est plus élevée aux indices où la perte de monotonie a lieu (l'effet induit par un outlier quand on considère plus de voisins pour le test d'appartenance à la même droite est minimisé). Des impacts sont « remontés » afin de rendre la fonction cumulative la plus monotone possible. Il peut alors être extrait des segments de plus longue taille, mais certains trous subsistent et la monotonie ne peut toujours pas être utilisée pour l'extraction de formes. Ainsi l'algorithme développé détectera le plus long segment entre deux trous successifs dans l'accumulateur.

3.2.3.2.2 Phénomène de recouvrement

Dans le cas où un objet est visible par plusieurs faces, il peut exister un phénomène de recouvrement entre des triangles successifs dans l'accumulateur. Ce phénomène peut avoir différentes sources. Un objet peut ne pas être strictement polygonal (carrosserie, pare-choc, ...). Le modèle choisi se basant sur une représentation segment, les courbes sont ainsi approchées par un ensemble de segments. Plusieurs impacts consécutifs peuvent alors être agrégés à deux segments distincts, et la césure entre deux triangles dans la fonction cumulative n'est plus aussi nette. Ce phénomène peut aussi s'expliquer par la présence d'outliers entre les extrémités des segments. Ces outliers interdisent la validation du critère 3.8 et ne peut mener à la détection du segment de taille maximale.




FIGURE 3.4 – (a) Mesures bruitées associées à un véhicule situé en $(-3.7, 6.2)$ (b) Accumulateur calculé selon la méthode dans le sens ascendant (c) Accumulateur construit dans le sens descendant

La figure 3.4(a) montre les impacts télémétriques d'un objet visible par deux faces. La figure 3.4(b) montre l'accumulateur (calcul par sens ascendant) et illustre le phénomène de recouvrement de formes. Le calcul de la fonction cumulative par une autre méthode (fig. 3.4(c) pour le sens descendant par exemple) ne peut résoudre ce problème mais permet tout de même de réduire la perte de monotonie (trous).

3.2.3.3 Méthode d'extraction de formes dans des données bruitées et segmentation finale

L'objectif est d'extraire les segments de taille maximale, et donc les triangles dont la base ont la plus grande longueur. La monotonie de l'accumulateur reste le critère principal pour l'extraction d'éléments : le premier segment détecté est le plus long qui vérifie cette propriété (il s'agit donc du plus grand pic de la fonction cumulative).

La première itération du processus se déroule en extrayant l'indice i_{max} du maximum de CF . Un test est alors effectué pour savoir si l'enveloppe de CF peut contenir un triangle centré en i_{max} de hauteur $CF(i_{max})$ en respectant la contrainte de monotonie :

$$\forall i \in \llbracket i_{max} - CF(i_{max}), i_{max} + CF(i_{max}) \rrbracket, CF(i) \leq CF(i_{max}) - |i_{max} - i| \quad (3.12)$$

Si l'inégalité est vérifiée alors le triangle est conservé. Sinon, la fonction V définie par l'équation 3.9 est mise à jour, on détermine la fonction CF correspondante et on répète le processus en considérant un voisinage décrétementé $CF(i_{max}) - 1$.

En raison des perturbations dans l'accumulateur, la valeur de CF correspondante à l'indice extrait est donc plus faible que dans le cas idéal et détermine la longueur du segment en terme de nombre d'impacts. Les inliers de ce segment sont alors retirés de l'accumulateur ($CF = 0$ pour les indices) et la détection du plus long segment suivant s'effectue récursivement jusqu'à ce que chaque élément de CF corresponde à un segment (et donc à un triangle). La méthode développée est résumée dans l'algorithme 5.

```

Entrées : un ensemble  $\mathcal{P} = \{P_1, \dots, P_{n_{max}}\}$  d'impacts
            l'accumulateur  $CF$  correspondant à la scène
Sorties : un ensemble  $\mathcal{S}$  de segments définies par longueur et point central
            un ensemble  $\mathcal{T}$  d'inliers de chaque segment
 $l = 0$ ; // Indicateur du nombre de segments
tant que  $\exists i / CF(i) \neq 0, \forall i = \{1, \dots, n_{max}\}$  faire
     $i_{max} = \arg \max_i CF(i)$ 
    si  $CF$  est strictement monotone par morceaux sur les intervalles
         $[i_{max} - CF(i_{max}), i_{max}]$  et  $[i_{max}, i_{max} + CF(i_{max})]$  alors
            Utilisation de l'algorithme 4
             $V(i, j) = 0, \forall i \in \llbracket i_{max} - CF(i_{max}), i_{max} + CF(i_{max}) \rrbracket$  et  $\forall j = \{1, \dots, CF(i_{max})\}$ 
        sinon
             $V(i, j_{max}^i) = 0, \forall i \in \llbracket i_{max} - CF(i_{max}), i_{max} + CF(i_{max}) \rrbracket$  et
             $j_{max}^i = \arg \max_j V(i, j)$ 
             $CF(i) = \max_k V(i, k)$ ; // Mise à jour de l'accumulateur
        si l'enveloppe de la fonction  $CF$  respecte la condition de monotonie alors
            Utilisation de l'algorithme 4
             $V(i, 1 \dots CF(i_{max})) = 0, \forall i$  sur le nouvel intervalle
        sinon
            Répétition de l'opération sur un voisinage  $CF(i_{max}) - 1$  jusqu'à satisfaction de la
            condition de monotonie
        fin
    fin
fin

```

Algorithme 5 : Détection de triangles dans un accumulateur perturbé par le bruit de mesure

Les figures 3.5 illustrent la méthode pas à pas employée pour la détermination successive des plus grands segments dans le cas où l'accumulateur souffre de perte de monotonie (phénomène de trous). La méthode d'extraction a ici été appliquée sur l'accumulateur construit dans le sens ascendant. Le premier triangle, correspondant au plus long segment, est extrait (noté 1st step), l'accumulateur est ensuite mis à jour et on répète le processus. Finalement, après récupération de l'ensemble des inliers, les paramètres du segment sont déterminés de la même manière que dans la section 2.5.3. La figure 3.5(b) montre les résultats finaux de la méthode de segmentation sans aucune modification : un contrôle de taille peut en effet être effectué afin d'exclure les segments trop petits mais qui ont été conservés ici pour l'illustration.

Le phénomène de recouvrement induit une extraction d'éléments pouvant s'apparenter à une




FIGURE 3.5 – (a) Extraction d'éléments à partir de l'accumulateur construit en sens ascendant pour un phénomène de trous (b) Résultats de la segmentation associés sans exclusion de segments

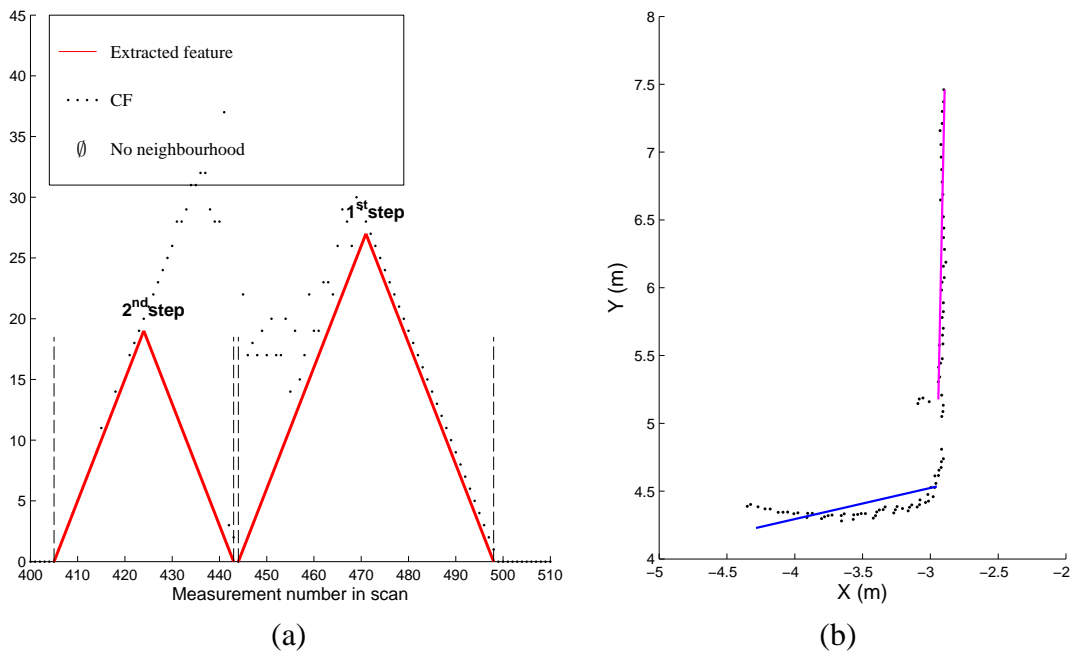


FIGURE 3.6 – (a) Extraction d'éléments à partir de l'accumulateur construit en sens ascendant pour un phénomène de recouvrement (b) Résultats de la segmentation associés

configuration d'hypothèses multiples, puisque plusieurs triangles peuvent être compris dans l'enveloppe de CF . Plusieurs solutions sont alors envisageables pour une segmentation efficace. La figure 3.6 illustre ce processus qui scinde alors la fonction CF en plusieurs fonctions de taille maximale qui respectent la contrainte de monotonie. La méthode propose donc de détecter les plus longs segments et la courbe montrée sur la figure 3.6(b) est ainsi approchée par un seul segment.

3.2.3.4 Appariement des points orphelins

À la sortie de l'étape de segmentation, les paramètres de chaque droite sont déterminés par minimisation quadratique. L'un des problèmes de cette méthode d'extraction peut être la non-association de points du scan en raison du bruit de mesure ou de la conception de la méthode qui n'envisage que la possibilité d'extraire un nombre impair d'impacts. La figure 3.7 montre un cas où le triangle maximal a pu être extrait mais il reste un point non associé.




FIGURE 3.7 – Exemple d'impact non associé (cerclé à moitié) après le processus d'extraction de formes (triangle noir)

Les points dits orphelins (points immédiatement voisins à un ensemble d'inliers) sont stockés en mémoire et utilisés en fin de processus. Une fois les paramètres de la droite relative à ces points calculée, une association basée sur une distance de Mahalanobis est alors effectuée. Si on note (ρ_d, θ_d) les paramètres de la droite extraite, et $P_i = (\rho_i, \theta_i)$ un impact orphelin, ce point sera inclus dans l'ensemble des inliers si le point projeté $P'_i = (\rho'_i, \theta_i)$ vérifie :

$$d_{M_i M'_i} = (\rho'_i - \rho_i)(\sigma_\rho^2)^{-1}(\rho'_i - \rho_i) \leq \epsilon \quad (3.13)$$

Si le point est associé, alors les paramètres (ρ_d, θ_d) de la droite sont de nouveau calculés en incluant cette mesure. La figure 3.7 illustre ce phénomène. Le point orphelin d'indice 331 n'est, dans un premier temps, pas associé à cette droite par le processus d'extraction mais le sera ensuite puisque l'inégalité 3.13 est vérifiée.

Finalement le diagramme 3.8 résume les étapes successives de la méthode SIP.

3.3 Extraction des données de la zone d'observation

L'une des difficultés dans les systèmes de perception est de déterminer les données qui représentent les objets présents dans une zone d'intérêt, de celles qui proviennent d'éléments extérieurs et n'apportent donc aucune information potentielle au système que ce soit pour le processus global de




FIGURE 3.8 – Représentation schématique de la méthode SIP

suivi ou pour la seule étape de détection étudiée dans ce chapitre. Nous proposons dans ce manuscrit une méthode d'extraction de données observables basée sur une utilisation conjointe des données GPS du véhicule porteur et de données cartographiques. Elle présente l'intérêt d'automatiser un tel processus en convertissant les données télémétriques dans un repère orthonormé, et ne nécessite pas l'apport d'autres capteurs tels que la caméra par exemple. Cette méthode est détaillée dans l'annexe B.

3.4 Évaluation de la méthode de détection SIP

3.4.1 Présentation

La méthode SIP a été évaluée sur différentes données synthétiques et réelles issues de scénarios routiers. Puisqu'il est possible d'imaginer plusieurs modélisations selon les objets suivis (qui peuvent être approchés par des polygones), et que le choix de la modélisation n'influe pas sur la qualité de la segmentation, les centres de gravité des véhicules n'ont pas été déterminés pour l'évaluation. Pour une comparaison, les méthodes les plus utilisées dans la segmentation de données issues des capteurs télémétriques, à savoir Split-and-Merge, Incremental, RANSAC et Hough, ont été implémentées. Un protocole d'évaluation commun a été élaboré.

Quelles que soient les données (synthétiques ou réelles), un clustering non adaptatif peut éventuellement être mis en œuvre pour optimiser les résultats et réduire le coût calculatoire. La détermination du seuil fixe pour ce clustering est calculée à chaque scan proportionnelle aux distances inter-impacts par une simple moyenne. L'effet de l'utilisation ou non d'un tel clustering sera étudié sur les performances des méthodes de segmentation.

Une fois l'extraction des segments effectuée, une procédure de fusion est également proposée pour regrouper les segments appartenant aux mêmes surfaces de la scène. Cette procédure correspond à la partie Merge implémentée dans la méthode Split-and-Merge (section 2.5.5.2). Cette procédure tient compte de l'orientation des droites supports mais pas de leur distance au capteur. Un simple test sur ces distances est ajouté. Notons S_1 et S_2 deux segments détectés de droites supports

(ρ_d^1, θ_d^1) et (ρ_d^2, θ_d^2) . Si S_1 et S_2 ont vérifié le test angulaire (éq. 2.30), ils seront fusionnés si :

$$|\rho_1 - \rho_2| \leq \epsilon_\rho \quad \text{avec } \epsilon_\rho = 0.25\text{m, par exemple} \quad (3.14)$$

Une précaution est également ajoutée pour préserver la description de la scène en limitant la fusion de deux segments appartenant à deux objets distincts. Un test sur les distances entre les extrémités des segments consécutifs est alors réalisé. Pour deux segments S_1 et S_2 d'extrémités respectives $(e_1^{S_1}, e_2^{S_1})$ et $(e_1^{S_2}, e_2^{S_2})$ et organisés dans le sens du balayage, deux segments seront fusionnés si :

$$d(e_2^{S_1}, e_1^{S_2}) \leq \epsilon_e \quad \text{avec } \epsilon_e = 0.4\text{m, par exemple} \quad (3.15)$$

Lorsque deux segments passent ces différents tests, ils sont alors fusionnés en un seul et les nouveaux paramètres sont alors calculés en utilisant l'intégralité des inliers.

3.4.2 Données synthétiques

3.4.2.1 Scénario utilisé

Pour évaluer les méthodes de segmentation, un ensemble d'acquisitions indépendantes les unes des autres est considéré. Une zone d'observation est définie autour du véhicule porteur du télémètre, et sept véhicules y sont aléatoirement disposés (sans prise en compte de la plausibilité de la configuration obtenue), avec comme seule contrainte la distance entre les véhicules. Les dimensions d'un objet sont celles d'un véhicule de moyenne gamme.

Le capteur télémétrique synthétique possède les caractéristiques suivantes :

- portée : 100m
- résolution angulaire : $\alpha = 0.25^\circ$
- ouverture angulaire : $\theta_{min} = 10^\circ$, $\theta_{max} = 170^\circ$
- écart-type du bruit de mesure possible sur la distance : $\sigma_\rho = 0.03\text{m}$, 0.05m ou 0.1m

Conformément aux recommandations du constructeur, le bruit de mesure sur la composante angulaire des impacts est supposé négligeable.

1000 réalisations de Monte Carlo de cette scène sont alors effectuées afin d'obtenir une évaluation sur un nombre élevé de segments. La figure 3.9 illustre trois exemples de scans synthétiques obtenus avec 7 véhicules visibles. Le nombre total de segments N_{tot} , provenant des véhicules mais aussi des barrières limitant la zone d'observation, est connu pour l'ensemble des réalisations.

3.4.2.2 Critères d'évaluation

Trois critères ont été sélectionnés pour l'évaluation des méthodes de segmentation : la précision, l'exactitude et le coût calculatoire. Le calcul des erreurs nécessite un appariement entre les segments détectés et les segments décrivant effectivement la scène, parfaitement connus en données synthétiques. Cette procédure d'association reprend les mêmes critères de fusion sur l'orientation




FIGURE 3.9 – Échantillons de scans synthétiques utilisés pour l'évaluation des méthodes de segmentation.

(éq. 2.30) et la distance (éq. 3.14) du paragraphe précédent. Parmi les associations ainsi déterminées, il convient d'effectuer également un test sur les extrémités, à savoir :

- si les projections orthogonales des deux extrémités du segment détecté sont situés sur le segment théorique, alors le segment est associé ;
- si seulement une des projections des extrémités appartient au segment, un test sur la distance entre l'extrémités et celles du segment théorique est effectué (éq. 3.15). S'il est vérifié, le segment est associé ;
- sinon, le segment détecté est considéré comme fausse alarme.

Le détecteur est tout d'abord évalué en terme de **précision** d'estimation des paramètres (ρ_d, θ_d) des segments de la scène. On calcule l'écart-type de l'erreur d'estimation de chacun de ces paramètres par :

$$\sigma_{\rho_d} = \sqrt{\frac{1}{N_{mat} - 1} \sum_{i=1}^{N_{mat}} (e_{\rho}^i - \bar{e}_{\rho})^2} \quad \text{et} \quad \sigma_{\theta_d} = \sqrt{\frac{1}{N_{mat} - 1} \sum_{i=1}^{N_{mat}} (e_{\theta}^i - \bar{e}_{\theta})^2} \quad (3.16)$$

où

- N_{mat} est le nombre total d'associations entre segments détectés et segments théoriques,
- e_{ρ}^i (resp. e_{θ}^i) est l'erreur en distance (resp. orientation) pour une association et
- \bar{e}_{ρ} (resp. \bar{e}_{θ}) est la moyenne de ces erreurs sur l'ensemble des associations.

Le détecteur est ensuite évalué en terme d'**exactitude**. En effet, les méthodes évaluées peuvent engendrer des erreurs de segmentation, à savoir des segments détectés sans existence réelle (fausse alarme) et des segments existants mais non détectés (non-détections). Pour l'ensemble des réalisations, notons N_{ND} le nombre de non-détections, N_{FA} le nombre de fausses alarmes, N_{tot} le nombre total de segments théoriques et N_{extr} le nombre total de segments extraits par les algorithmes. L'exactitude est alors évaluée à partir de trois paramètres :

- le taux de détection $TruePos$ qui représente la proportion de segments détectés qui ont effec-

tivement été associés avec les segments théoriques de la scène :

$$TruePos = \frac{N_{tot} - N_{ND}}{N_{tot}} \quad (3.17)$$

- le taux de fausse alarme *FalsePos* qui est la proportion de segments non associés parmi les segments extraits :

$$FalsePos = \frac{N_{FA}}{N_{extr}} \quad (3.18)$$

- *Mean Seg. Length* qui est la taille moyenne des segments extraits. Cette quantité définit la compacité de la scène. En effet, pour un taux de détection donné, une valeur élevée de ce paramètre indique une description plus compacte de la scène comparativement à une valeur plus faible.

Ces indicateurs d'exactitude sont très importants puisqu'ils conditionnent directement l'efficacité des systèmes de suivi. Un taux de fausse alarme élevé présente l'inconvénient de générer un nombre important de fausses pistes pouvant perturber fortement le processus global. La compacité de la scène détermine le nombre d'objets à considérer dans le processus de suivi. Par contre, les cas de non-détection peuvent être gérés par les filtres qui permettent l'intégration temporelle au cours du suivi [BSF87].

Enfin, le **coût calculatoire** est déterminé pour chaque méthode. Dans un système de détection d'objets, la vitesse d'exécution est un paramètre crucial en raison de la quantité de données à traiter. Les méthodes ont été implémentées sur la même machine avec le même langage de programmation haut niveau (Matlab[®]). Il s'agit là de montrer une échelle de valeurs des coûts calculatoires de chaque méthode. La méthode la plus rapide sera prise comme référence et les temps d'exécution des autres méthodes seront exprimés par un facteur.

3.4.2.3 Résultats des évaluations

Les premiers résultats sont détaillés pour un bruit de mesure standard sur la distance dont l'écart type est $\sigma_\rho = 0.03\text{m}$ (tableau 3.2).

La difficulté de conception d'un système de détection est de maximiser la probabilité de détection tout en minimisant celle de fausse alarme. Avant l'évaluation de notre méthode SIP, nous nous focalisons sur les méthodes existantes. Il est à noter que toutes ces méthodes (sauf Hough) ont été implémentées avec et sans clustering non adaptatif. Les résultats confirment alors la rapidité et l'efficacité de la méthode Split-and-Merge (SM). Elle dispose du taux de détection le plus élevé et elle sera la référence pour la détermination du coût calculatoire. Par contre, ses performances sont atténuées par une augmentation relative du taux de fausse alarme. La sensibilité de SM aux outliers induit une taille plus petite des segments détectés et une précision d'estimation plus faible sur les paramètres ρ_d et θ_d .

La méthode Incremental (Inc.) présente des performances en détection assez similaires à SM et elle est même plus précise en estimation (34% d'amélioration pour le paramètre θ_d), décrivant la

Algorithme	Nb Seg. Extraits (N_{extr})	Exactitude			Précision		Coût Calc.	
		$TruePos$ (%)	$FalsePos$ (%)	$Mean Seg.$ $Length$ (m)	σ_{ρ_d} (m)	σ_{θ_d} (deg)	Ratio (Hz)	
SIP + clust.	19967	87.7	14.1	8.61	0.35	1.14	1.6	
SIP	19828	87.7	13.9	8.66	0.35	1.09	1.9	
SM + clust.	25111	88.9	19.1	6.69	0.45	2.21	1	
SM	25854	88.6	20.1	6.69	0.46	2.28	1.3	
Inc. + clust.	19531	83.3	18.9	8.36	0.38	1.5	13.3	
Inc.	19677	71.0	31.5	13.79	0.38	1.5	13.3	
RANSAC + clust.	20547	78.5	11.7	7.97	0.33	1.43	30	
RANSAC	25288	78.6	12.2	6.47	0.41	2.61	13.8	
HOUGH + clust.	22161	81.3	12.5	9.72	0.36	1.63	3600	

TABLE 3.2 – Comparaison de la méthode SIP avec d'autres algorithmes de détection ($\sigma_\rho = 0.03m$, $N_{tot} = 18722$)

scène par de plus longs segments. Cependant, le ratio coût calculatoire contrebalance ces performances puisque la méthode est beaucoup plus lente que SM (facteur 13).

RANSAC présente lui aussi un taux de détection assez élevé, et un taux de fausse alarme plus faible comparé à SM. Les écarts-types sur les erreurs sont également plus faibles avec une description plus compacte de la scène (taille moyenne des segments supérieure de 20% par rapport à SM), mais une nouvelle fois le coût calculatoire pénalise ce type de méthode pour une implémentation en ligne.

Enfin, l'approche basée sur la transformée de Hough possède des résultats similaires à RANSAC et Inc. en termes de précision et d'exactitude mais le coût calculatoire est rédhibitoire. Ce facteur peut être diminué en discrétisant de manière plus grossière l'espace des paramètres de recherche au détriment de la précision d'estimation.

Le tableau comparatif 3.2 montre les bénéfices apportés par notre méthode. En effet, SIP propose le meilleur compromis entre exactitude - précision d'estimation et coût calculatoire, légèrement plus élevé que SM. De manière plus détaillée, la méthode SIP propose un taux de détection pratiquement égal à celui de SM, avec une probabilité de fausse alarme plus faible (réduction de l'ordre de 25%). La compacité de la description est plus élevée tandis que l'estimation des paramètres est plus précise (division par 2 pour le paramètre θ_d). La méthode SIP peut segmenter un scan à une fréquence maximale de 22.5Hz qui peut être améliorée en utilisant un langage de programmation bas niveau. Cette fréquence de segmentation est néanmoins compatible pour une utilisation sur les données des télémètres qui ont une fréquence d'acquisition de l'ordre de 10Hz.

Une autre lecture de ce tableau de comparaison montre que l'apport du clustering est ambigu pour SIP puisque certains critères d'évaluation sont légèrement dégradés ($Mean Seg. Length$, $FalsePos$ et σ_{θ_d} et). L'une des raisons que l'on peut avancer intègre un partitionnement qui peut être assimilé à un clustering. Pour les autres méthodes, ce clustering est parfois indispensable pour obtenir des bonnes performances (méthode Incremental par exemple). On verra par la suite que l'orientation des véhicules et le taux de fausse alarme sont importants pour le processus de suivi. On privilégiera donc la méthode SIP sans clustering évitant ainsi le choix d'un seuil qui peut engendrer des erreurs

de segmentation en raison d'un mauvais partitionnement.

Pour un bruit de mesure standard, la méthode SIP fournit une amélioration significative des résultats en détection comparés à ceux de la méthode SM de référence. Un critère d'évaluation sur la robustesse face au bruit de mesure permettra de confirmer cette amélioration.

3.4.2.4 Robustesse face au bruit de mesure

Deux autres niveaux de bruits de mesure ont été considérés pour l'évaluation de la méthode SIP. L'approche basée sur la transformée de Hough n'entre plus dans l'évaluation en raison de son coût calculatoire et la meilleure de chacune des 4 autres est conservée. Le tableau 3.3 montre les résultats pour un bruit de mesure $\sigma_\rho = 0.05\text{m}$.

Algorithme	Nb Seg. Extraits (N_{extr})	Exactitude			Précision	
		<i>TruePos</i> (%)	<i>FalsePos</i> (%)	<i>Mean Seg.</i> <i>Length</i> (m)	σ_{ρ_d} (m)	σ_{θ_d} (deg)
SIP	19940	86.1	15.8	8.7	0.45	1.45
SM + clust.	25555	86.9	23.2	6.57	0.52	2.31
Inc. + clust.	18884	79.6	20.4	8.52	0.46	1.63
RANSAC + clust.	20919	76.7	13.1	7.77	0.47	2.13

TABLE 3.3 – Comparaison de la méthode SIP avec d'autres algorithmes de détection ($\sigma_\rho = 0.05\text{m}$, $N_{tot} = 18722$)

Les résultats confirment la tendance observée lors de l'évaluation avec un bruit de mesure d'écart-type $\sigma_\rho = 0.03\text{m}$. La méthode SIP devient même meilleure en terme de précision d'estimation que RANSAC et SIP propose une probabilité de détection toujours similaire à SM avec même un écart sur la probabilité de fausse alarme qui augmente. L'écart en compacité augmente légèrement par rapport à SM et diminue par rapport à l'approche Incremental, ce qui n'est pas en soi un critère totalement négatif. Cependant, tous les autres résultats font de SIP une meilleure méthode de segmentation qu'Incremental. Enfin, la table 3.4 présente les résultats pour un bruit de mesure d'écart-type élevé pour ce type de données ($\sigma_\rho = 0.1\text{m}$). La méthode SIP conserve les mêmes bénéfices que ceux décrits précédemment. Il est à noter que notre méthode n'a pas besoin de « clustering », même en cas de bruit fort, car celui-ci est inclus dans la conception de la méthode. Cela représente un réel avantage en raison de la difficulté d'estimation de la distance inter-impacts.

3.4.3 Données réelles

3.4.3.1 Protocole d'étude

La méthode SIP a ensuite été validée sur les données réelles présentées dans la section 1.3.2. On rappelle que le télémètre utilisé est un IBEO avec un écart-type de bruit de mesure sur la distance $\sigma_\rho = 0.05\text{m}$. Dans le scénario considéré, le télémètre est positionné sur un véhicule porteur qui évolue à vitesse constante sur une ligne droite. La séquence dure 45s fournissant un total de

Algorithme	Nb Seg. Extraits (N_{extr})	Exactitude			Précision	
		$TruePos$ (%)	$FalsePos$ (%)	$Mean Seg.$ $Length$ (m)	σ_{ρ_d} (m)	σ_{θ_d} (deg)
SIP	19909	79.6	21.9	8.84	0.60	2.35
SM+ clust.	26290	81.6	32.1	6.61	0.62	2.65
Inc. + clust.	18785	69.2	30.4	9.1	0.57	2.26
RANSAC + clust.	21283	69.7	24.0	7.82	0.62	2.99

TABLE 3.4 – Comparaison de la méthode SIP avec d’autres algorithmes de détection ($\sigma_{\rho} = 0.1m$, $N_{tot} = 18722$)

450 acquisitions. Pendant la séquence, deux véhicules évoluent dans l’environnement, l’un d’eux masquant partiellement ou totalement le second (pour 20% des acquisitions).

Les figures 3.10 montrent des exemples de scans réels où les véhicules sont cerclés.. Le scan de droite illustre un cas d’occultation partielle du véhicule le plus éloigné.




FIGURE 3.10 – Échantillons issus de la séquence réelle.

La difficulté pour évaluer les méthodes de détection en données réelles réside dans l’absence de vérité terrain. Deux processus d’évaluation ont été imaginés :

- le premier consiste en une segmentation totale de l’environnement perçu par le télémètre : véhicules, barrières, murs, ... Le but est d’évaluer la compacité de la description dans sa globalité. Cependant, pour toutes les méthodes, les segments détectés de taille trop petite (taille inférieure à 25cm) sont exclus de l’évaluation.
- La seconde évaluation est faite en limitant la zone d’observation à la route afin d’obtenir une segmentation des seuls véhicules. Un processus de restriction de la zone d’observation, basé sur l’utilisation conjointe de cartes routières et de données GPS a été mis en place (annexe B). Des exemples sont donnés sur les figures B.5. Afin d’effectuer la comparaison entre les méthodes précédemment conservées, il est d’abord nécessaire de connaître le nombre de segments de la scène observée. Sans vérité terrain, ce nombre est obtenu de manière supervisée à partir de la connaissance du nombre de véhicules présents et de leur position à chaque instant.

En situation réelle, les probabilités de détection et de fausse alarme ne peuvent donc pas être calculées. Cependant, un critère expérimental R , simplement défini comme le ratio entre le nombre de segments détectés et le nombre de segments réels dans la zone d'observation, peut représenter une idée de la compacité de la description. Plus il est proche de 1 et plus le nombre de segments détectés approche le nombre théorique de segments

3.4.3.2 Résultats

Méthode	SIP	SM	Incremental	RANSAC
Segments détectés (environnement complet)	19240	31726	21330	22341
Segments détectés (zone d'observation)	1117	1669	1162	1487
R	1.07	1.60	1.11	1.42

TABLE 3.5 – Résultats de détection sur la séquence réelle (zone d'observations restreinte : 1043 segments théoriques)

Comme le montre le tableau 3.5 pour la détection sur l'ensemble des acquisitions, la méthode SIP est celle qui fournit le moins de segments pour l'environnement complet. Après SIP, la méthode Incremental est celle qui fournit une description plus compacte, puis vient RANSAC et enfin SM. La raison d'une telle différence (+10000 segments pour SM par rapport à SIP) réside dans le choix du seuil du Split qui induit une découpe excessive des segments dû à la présence élevée d'outliers dans la séquence réelle.

Pour la détection restreinte à la zone routière, SIP est encore la méthode qui a besoin du moins de segments pour décrire les objets, avec un nombre proche de l'évaluation supervisée du nombre de segments. L'ordre établi entre les différentes méthodes demeure le même que celui trouvé pour la détection sur tout l'environnement. L'indicateur R valide la qualité de la compacité de la description et confirme l'avantage apporté par SIP.

Afin d'illustrer les résultats précédents, nous nous focalisons sur un détail d'une des acquisitions (fig. 3.11). Ces impacts représentent un véhicule relativement proche du capteur (nombre élevé) pour lequel la forme n'est pas exactement rectangulaire (pare-choc et passage de roue créant des outliers). La méthode SIP est la moins sensible à ces outliers et mène donc à une description compacte de l'objet. En effet, les mesures qui ne remplissent plus l'hypothèse gaussienne 3.8 sont considérés comme outliers. *A contrario*, RANSAC est peu sensible aux outliers mais génère beaucoup de segments et les deux autres méthodes créent des segments incompatibles avec notre modèle rectangulaire.

Dans les applications de transport (ou robotiques) où la segmentation est nécessaire, les objets peuvent être souvent être considérés comme polygonaux, même si cette hypothèse n'est pas toujours exacte en situations réelles en raison des surfaces rencontrées. Les figures 3.11 illustrent le comportement de ces différentes méthodes dans ce cas. De plus, une segmentation compacte, source de modélisation optimale et de limitation de fausse alarme, permet ainsi de moins perturber l'étape d'association du processus de suivi d'objets.




FIGURE 3.11 – Segments détectés pour l'acquisition #8 pour les méthodes : (a) SIP (b) SM (c) Inc. (d) RANSAC

3.5 Conclusion

Ce chapitre a permis de présenter une nouvelle méthode de détection de segments dans des données télémétriques. Les capteurs télémétriques délivrent des mesures en coordonnées polaires et la majorité des méthodes classiques (Split-and-Merge, Incremental, RANSAC, Hough) effectuent cette détection en appliquant une transformation de coordonnées (polaires-cartésiennes) qui ne préserve pas les statistiques du bruit de mesure. Les méthodes de détection utilisent en général la distance inter-impacts des points de l'acquisition, paramètre difficile à borner puisqu'elle est conditionnée par la position spatiale et l'orientation des objets perçus.

La méthode SIP développée permet d'apporter de nombreux avantages dans la détection de segments. Celle-ci traite d'abord les mesures brutes issues du capteur en coordonnées polaires pour les associer, par la définition d'un test statistique d'appartenance à une même droite. Ce test dépend uniquement de l'impact central du segment et d'un paramètre intrinsèque au capteur, la résolution angulaire α . Ce critère se construit en utilisant les propriétés d'invariance géométrique d'une droite polaire et ne dépend pas de la distance inter-impacts.

La méthode SIP proposée permet également d'effectuer un partitionnement basé modèle (à savoir le segment) et ne nécessite donc pas de clustering préalable, au contraire des autres approches pour lesquelles il est indispensable afin d'augmenter la précision d'estimation des paramètres des segments. À l'issue de ce partitionnement, la segmentation repose alors sur une extraction de formes qui permet de connaître l'ensemble des inliers d'une droite et d'en déterminer les paramètres par minimisation quadratique.

L'approche de détection SIP a été évaluée sur des données synthétiques présentant des configurations aléatoires de placement de véhicules avec des bruits différents. Ces diverses évaluations ont permis de montrer des bénéfices significatifs de détection en termes de minimisation de fausses alarmes et de précision d'estimation des paramètres. La méthode est moins sensible aux outliers

comparée aux autres méthodes implémentées et permet une description minimale de la scène avec moins de segments extraits. L'évaluation sur données réelles a enfin permis de confirmer l'intérêt de la méthode avec une meilleure compacité de description de l'environnement.

Ces différents avantages peuvent sensiblement améliorer le processus de suivi. En effet, le bénéfice conjoint d'une estimation plus précise des paramètres des segments et d'une réduction du taux de fausse alarme permet de réduire le nombre de pistes à considérer, à chaque instant, dans un processus d'association et de suivi d'objets. Toute la chaîne de traitement peut donc être améliorée avec la méthode SIP, et c'est donc maintenant ce processus suivi qui va être présenté.

Deuxième partie

Détection et suivi de véhicules dans les données télémétriques

Chapitre 4

Suivi multi-objets : état de l'art

4.1 Introduction

Le suivi multi-cibles fait partie intégrante d'applications telles que la surveillance ou l'anti-collision. Les méthodes de suivi prennent en compte, à intervalles de temps réguliers, des mesures bruitées provenant de capteurs et estiment les paramètres des modèles de la dynamique des cibles. La théorie du filtrage, et plus particulièrement l'inférence bayésienne, fournit un cadre de travail universellement utilisé dans les méthodes de suivi. Elle met à disposition des outils qui permettent aussi d'évaluer les incertitudes d'estimation dynamique. La densité de probabilité *a posteriori* de l'état sachant les observations précédentes est récursivement prédite en utilisant un modèle d'état et corrigée avec l'apport des nouvelles observations à chaque instant.

Dans une première partie, après avoir évoqué rapidement les méthodes classiques de filtrage, les méthodes de Monte Carlo séquentielles sont détaillées pour traiter la problématique de l'estimation dynamique dans un cas très général. Ces méthodes sont alors considérées comme des méthodes de suivi mono-cible mono-capteur.

Dans un second temps, quelques approches de suivi multi-cibles sont présentées. Deux axes de recherche ont alors été exploités : l'un permet de considérer chaque cible individuellement et se ramène donc au cas du suivi mono-cible. La problématique associée consiste à connaître quelles mesures entrent dans le processus de correction de chaque cible par des méthodes d'association : les méthodes d'association probabilistes telles que Joint Probabilistic Data Association (JPDA) ou Multiple Hypothesis Tracking (MHT) sont par exemple détaillées. La seconde approche consiste à considérer le problème de suivi de manière différente et est dérivée du filtre Probability Hypothesis Density (PHD). En introduisant la théorie des ensembles finis aléatoires (RFS), ces approches sont une alternative implémentable du suivi multi-cibles bayésien optimal. En plus d'estimer classiquement l'état des cibles en sortie des algorithmes, celles-ci estiment de manière conjointe la cardinalité de l'ensemble des cibles présentes.

4.2 Filtrage bayésien

4.2.1 Estimation de processus markoviens et notion de modèles

Considérons un processus stochastique X dont on cherche à estimer l'évolution au cours du temps. X n'est pas directement observable mais il l'est indirectement par un processus stochastique Z représentant les mesures fournies par différents capteurs et pouvant délivrer des informations différentes. Le processus X est supposé markovien : son état présent ne dépend que de son état immédiatement précédent, propriété que l'on peut résumer sous la forme suivante :

$$p(X_t|X_{t-1}, X_{t-2}, \dots, X_0) = p(X_t|X_{t-1}) \quad (4.1)$$

La problématique générale du filtrage consiste à estimer le processus X à l'instant t à partir de $Z_{1:t}$, ensemble des observations jusqu'au temps t . Dans le cadre de cette thèse, on considère que les modèles reliant l'état et les observations sont connus. Ces modèles stochastiques permettent de prendre en considération des paramètres aléatoires ou mal connus. Le modèle reliant X_t à X_{t-1} est le modèle d'évolution d'état (ou modèle de dynamique). Il est représenté par la densité de probabilité d'évolution $p(X_t|X_{t-1})$. Le modèle reliant Z_t à X_t est le modèle d'observation (ou mesure) et il est représenté par la densité de probabilité $p(Z_t|X_t)$ (appelée vraisemblance).

Pour définir le problème de filtrage, on considère un système markovien à temps discret :

$$\begin{cases} X_t &= f(X_{t-1}) + W_t \\ Z_t &= h(X_t) + \nu_t \end{cases} \quad (4.2)$$

f : fonction de transition de l'état (modèle de dynamique)

h : fonction d'observation (modèle de mesure)

W_t : bruit de dynamique de loi connue

ν_t : bruit d'observation également de loi connue

La résolution de ce système passe par la construction d'un estimateur. Celle-ci est dictée par le choix d'un critère d'estimation en fonction du contexte. On note, au sens de ce critère, $\hat{X}_{t|t}$ l'estimateur optimal du processus X à l'instant t connaissant les observations Z jusqu'à l'instant t . Nous utilisons comme critère d'estimation la minimisation de la variance de l'erreur d'estimation. L'estimateur optimal est alors donné par :

$$\hat{X}_{t|t} = E(X_t|Z_{1:t}) = \int_{X_t} X_t p(X_t|Z_{1:t}) dX_t \quad (4.3)$$

La solution repose donc uniquement sur la connaissance de la densité de probabilité *a posteriori* $p(X_t|Z_{1:t})$. Dans le cadre markovien, des solutions sont établies pour estimer de manière récursive cette densité de probabilité. Supposons la loi $p(X_0|Z_0) \equiv p(X_0)$ connue et la densité $p(X_{t-1}|Z_{1:t-1})$ estimée à l'instant précédent. La partie prédictive de la récursivité permet de connaître la densité *a*

priori et est obtenue à l'aide de l'équation de Chapman-Kolmogorov sous l'hypothèse de markovieneté du processus X :

$$p(X_t|Z_{1:t-1}) = \int_{X_{t-1}} p(X_t|X_{t-1})p(X_{t-1}|Z_{1:t-1})dX_{t-1} \quad (4.4)$$

L'apport de la mesure Z_t permet la mise à jour de la densité *a priori* en utilisant la règle de Bayes :

$$p(X_t|Z_{1:t}) = \frac{p(Z_t|X_t)p(X_t|Z_{1:t-1})}{p(Z_t|Z_{1:t-1})} \quad (4.5)$$

La constante de normalisation est donnée par :

$$p(Z_t|Z_{1:t-1}) = \int_{X_t} p(Z_t|X_t)p(X_t|Z_{1:t-1})dX_t \quad (4.6)$$

Les relations 4.4 et 4.5 forment la base de la récursivité de la solution qui est alors donnée par :

$$p(X_t|Z_{1:t}) = \frac{\int_{X_{t-1}} \prod_{k=1}^t p(X_k|X_{k-1})p(X_0) \prod_{k=0}^t p(Z_k|X_k)dX_{1:t-1}}{\int_{X_t} \prod_{k=1}^t p(X_k|X_{k-1})p(X_0) \prod_{k=0}^t p(Z_k|X_k)dX_{1:t}} \quad (4.7)$$

L'équation 4.7 permet de conclure que la problématique du filtrage repose sur la connaissance de deux densités de probabilités :

- la loi de transition $p(X_t|X_{t-1})$
- la loi d'observation $p(Z_t|X_t)$

Le filtrage bayésien permet de construire récursivement et exactement la densité *a posteriori* mais qui en pratique est rarement calculable de manière analytique. Des méthodes ont donc été développées pour approcher cette solution et quelques-unes sont développées dans la suite de ce manuscrit.

4.2.2 Filtrage de Kalman

Le filtre de Kalman [Kal60] est très largement utilisé dans des domaines variés (navigation, biologie, économie, ...) [BSL93]. Il apporte la solution optimale du problème de filtrage à minimum de variance sous les hypothèses :

- condition initiale gaussienne ;
- de linéarité des fonctions de transition et d'observation ;
- d'additivité des bruits gaussiens de dynamique et de mesure, lesquels doivent être décorrélés.

Ces hypothèses garantissent la gaussianeté de la densité *a posteriori* $p(X_t|Z_{1:t})$ qui est donc entièrement définie par ses deux premiers moments.

Si les conditions restrictives du filtre de Kalman ne sont plus respectées, le filtre de Kalman étendu (EKF) fait alors l'hypothèse que la densité de probabilité *a posteriori* $p(X_t|Z_{1:t})$, qui n'est plus gaussienne, peut être approchée par une densité gaussienne et donc calculable analytiquement.

Il s'agit de la solution la plus directe [JU97] qui se base sur une linéarisation locale des équations d'état autour de l'état estimé courant. Cette linéarisation permet de se ramener à un problème de filtrage linéaire que l'on résout par un filtre de Kalman.

L'approximation des modèles non linéaires par un équivalent localement linéarisé est convenable si les non-linéarités sont « faibles ». C'est un filtre largement utilisé dans de nombreuses applications [AMGC02, Mon03]. Cependant, la convergence de l'EKF n'est pas assurée car il repose sur une approximation locale des fonctions non linéaires.

En cas de fortes non-linéarités, le filtre de Kalman sans parfum (UKF) offre une alternative à l'EKF [JU97] en se basant sur l'idée qu'il est plus facile d'approximer une densité de probabilité qu'une fonction non linéaire. L'étape de linéarisation est remplacée par une technique d'échantillonnage de la densité de probabilité qui repose sur un ensemble de sigma-points qui sont propagés via les équations d'état du système. Ces sigma-points permettent d'évaluer précisément les deux premiers moments de la densité de probabilité *a posteriori* en évitant le biais dans leur estimation lors de la procédure de linéarisation de l'EKF. Le filtre UKF est plus robuste aux non-linéarités que l'EKF et montre des performances supérieures [WVdM00]. Il ne requiert aucun calcul de jacobienne et le coût calculatoire est similaire à celui de l'EKF. Lorsque la densité de probabilité $p(X_t|Z_{1:t})$ est éloignée de l'approximation gaussienne, d'autres méthodes ont été développées comme les estimateurs à somme de gaussiennes [SA71, AM79], un développement en moments tronqués [LAC97] ou alors des approches numériques basées sur des méthodes à grilles déterministes ou aléatoires [Ber99].

4.3 Méthodes de Monte Carlo séquentielles pour le filtrage non linéaire

L'idée des méthodes de Monte Carlo séquentielles est similaire à celle des méthodes à grilles déterministes, *i.e.* la densité de probabilité conditionnelle $p(X_t|Z_{1:t})$ est approchée par un ensemble de N nœuds pondérés d'un maillage aléatoire de l'espace d'état $\left\{ X_t^{(j)}, \omega_t^{(j)} \right\}_{j=1}^N$. L'objectif n'est donc plus la représentation analytique d'une densité de probabilité, mais de construire un ensemble d'échantillons distribués selon cette densité. Ces nœuds, appelés particules, sont alors propagés dans le temps en utilisant une distribution d'importance et sont pondérés avec la mesure disponible à l'instant t . Ces méthodes permettent d'approcher n'importe quel type de densité de probabilité *a posteriori*.

La formulation moderne de ces méthodes provient des travaux de Metropolis et Ulam [MRR⁺53]. Celles-ci étant particulièrement gourmandes en ressources calculatoires, ce n'est qu'à la fin des années 80 que leur utilisation est devenue possible dans la problématique du filtrage et que des méthodes spécifiques ont été développées : les méthodes de Monte-Carlo séquentielles, également dénommées filtrage particulaire [GSS93, DMNRS92, DMNRS93, Dou98].

Ces approches, dont un récapitulatif peut être trouvé en [AMGC02], regroupent un ensemble de méthodes qui permettent de résoudre numériquement des systèmes dont on ne sait pas calculer

analytiquement la solution. Elles sont largement utilisées dans de nombreux domaines tels que la navigation [CDMMS97, GGB⁺02], le traitement du signal [MNRS95, VADG02], la vision [ZCM04, SDG⁺08] et le suivi d'objets [BRL⁺09, SdOCY11].

4.3.1 Approximation des moments d'une densité de probabilité

La solution au problème de filtrage à minimum de variance est définie comme l'espérance de l'état conditionnelle aux mesures disponibles jusqu'à l'instant t :

$$\hat{X}_{t|t} = \int_{X_t} X_t p(X_t|Z_{1:t}) dX_t \quad (4.8)$$

Si l'on excepte quelques cas particuliers, cette intégrale est impossible à calculer analytiquement. Le problème de filtrage repose sur la connaissance de $p(X_t|Z_{1:t})$, qui représente en fait la densité de probabilité, solution du problème de filtrage. Les méthodes de Monte-Carlo permettent de délivrer une approximation discrète de l'intégrale pour évaluer numériquement l'équation 4.8.

Les méthodes de type Monte Carlo séquentielles consistent à construire une approximation de la densité de probabilité conditionnelle $p(X_t|Z_{1:t})$ en générant un nombre N de variables aléatoires $X_t^{(j)}$ indépendantes et identiquement distribuées (i.i.d) [DDFG01]. La densité de probabilité conditionnelle est alors approchée par N mesures de Dirac équipondérées de support $X_t^{(j)}$ qui assurent une discrétisation de l'espace d'état :

$$p_N(X_t|Z_{1:t}) = \frac{1}{N} \sum_{j=1}^N \delta_{X_t^{(j)}}(X_t) \quad (4.9)$$

En substituant la loi $p(X_t|Z_{1:t})$ par son approximation discrète $p_N(X_t|Z_{1:t})$ dans l'équation 4.8, on obtient :

$$\hat{X}_{t|t} = \int_{X_t} X_t \frac{1}{N} \sum_{j=1}^N \delta_{X_t^{(j)}}(X_t) dX_t = \frac{1}{N} \sum_{j=1}^N X_t^{(j)} \quad (4.10)$$

La loi faible des grands nombres assure la convergence de l'approximation de la loi de probabilité vers la loi conditionnelle lorsque $N \rightarrow \infty$:

$$\lim_{N \rightarrow \infty} p_N(X_t|Z_{1:t}) = p(X_t|Z_{1:t}) \quad (4.11)$$

Il est aussi possible par ce biais de connaître les moments de $p(X_t|Z_{1:t})$. Pour toute fonction g p -intégrable, considérons l'intégrale :

$$E(g(X_t)|Z_{1:t}) = \int_{X_t} g(X_t) p(X_t|Z_{1:t}) dX_t \quad (4.12)$$

Si on dispose de N échantillons distribués selon $p(X_t|Z_{1:t})$, la convergence presque partout est vérifiée :

$$E(g(X_t)|Z_{1:t}) \approx \frac{1}{N} \sum_{j=1}^N g(X_t^{(j)}) \xrightarrow[N \rightarrow \infty]{p.s.} \int_{X_t} g(X_t) p(X_t|Z_{1:t}) dX_t \quad (4.13)$$

La convergence dépend du nombre de particules N et montre l'avantage des tirages de Monte-Carlo. En échantillonnant avec un nombre suffisant de variables aléatoires suivant une loi, l'intégrale 4.8 se transforme en une simple somme. Mais cette solution est en pratique rarement possible à mettre en place puisqu'il faut être capable d'échantillonner selon la loi $p(X_t|Z_{1:t})$, inconnue *a priori*.

4.3.2 Échantillonnage d'importance

Pour contourner ce problème d'échantillonnage de la loi, il existe des méthodes afin de générer des échantillons à partir d'une distribution de probabilité quelconque. Ces méthodes possèdent un coût de calcul élevé, surtout si la densité de probabilité est multidimensionnelle. Des approches alternatives ont donc été proposées [DDFG01, DM04] et l'une des plus répandues est l'échantillonnage d'importance [GSS93, Dou98]. Le principe est d'utiliser une autre densité de probabilité $\pi(X_t|Z_{1:t})$ (dénommée distribution d'importance) à partir de laquelle on sait échantillonner. Son choix doit être fait avec soin, son support doit au moins contenir celui de $p(X_t|Z_{1:t})$.

Introduisons cette densité d'importance dans l'éq. 4.8. L'estimateur peut se réécrire :

$$\begin{aligned} \hat{X}_{t|t} &= \int_{X_t} X_t \frac{p(X_t|Z_{1:t})}{\pi(X_t|Z_{1:t})} \pi(X_t|Z_{1:t}) dX_t \\ &= \int_{X_t} X_t \tilde{\omega}_t \pi(X_t|Z_{1:t}) dX_t \end{aligned} \quad (4.14)$$

L'équation 4.14 permet donc de se ramener aux mêmes conditions que celles de l'équation 4.3 ce qui permet d'effectuer une approximation de l'espérance conditionnelle qui s'écrit :

$$\hat{X}_{t|t} = \sum_{j=1}^N \tilde{\omega}_t^{(j)} X_t^{(j)} \quad (4.15)$$

$\tilde{\omega}_t^{(j)}$ est le poids d'importance de chaque échantillon $X_t^{(j)}$ de la variable aléatoire X_t défini par :

$$\tilde{\omega}_t^{(j)} = \frac{p(X_t^{(j)}|Z_{1:t})}{\pi(X_t^{(j)}|Z_{1:t})} \quad (4.16)$$

Ce terme peut alors être développé à l'aide de la formule de Bayes :

$$\tilde{\omega}_t^{(j)} = \frac{p(Z_t|X_t^{(j)})p(X_t^{(j)}|Z_{1:t-1})}{p(Z_t|Z_{1:t-1})\pi(X_t^{(j)}|Z_{1:t})} \quad (4.17)$$

Dans cette expression, le calcul du poids nécessite la connaissance de la densité de probabilité $p(Z_t|Z_{1:t-1})$ qui n'est généralement pas accessible. Une manière de palier cette difficulté est alors de normaliser ces valeurs pour finalement obtenir le poids normalisé de chaque particule :

$$\omega_t^{(j)} = \frac{\tilde{\omega}_t^{(j)}}{\sum_{k=1}^N \tilde{\omega}_t^{(k)}} \quad (4.18)$$

Le choix de la distribution d'importance est un paramètre clé des méthodes de Monte-Carlo séquentielles. La figure 4.1 illustre le principe avec un échantillonnage pondéré d'une loi $p(x)$ par une densité d'importance $\pi(x)$ choisie gaussienne. On observe que ce choix est crucial pour l'exploration de l'espace d'état puisque dans ce cas les échantillons ne sont pas assez dispersés. Quelques distributions d'importance seront présentées dans les paragraphes suivants.




FIGURE 4.1 – Illustration de l'échantillonnage pondéré pour l'approximation d'une densité p par la distribution d'importance gaussienne π

4.3.3 Le filtrage particulaire

Ces techniques d'échantillonnage sont alors utilisées pour construire récursivement les équations du filtre particulaire. Celui-ci consiste à propager les échantillons pondérés (particules) de façon à avoir une approximation discrète de la loi $p(X_{0:t}|Z_{1:t})$. Il existe plusieurs filtres particuliers. L'échantillonnage d'importance de la loi amène au filtre générique SIS (Sequential Importance Sampling) [DDFG01, AMGC02, DMDJ06].

4.3.3.1 Filtrage particulaire SIS

L'idée sur laquelle s'appuient les filtres particuliers est de construire une approximation de la densité de probabilité $p(X_{0:t}, Z_{1:t})$ de manière récursive sous forme d'une grille à supports aléatoires. Sa formulation récurrente est donnée par :

$$p(X_{0:t}|Z_{1:t}) = p(X_{0:t-1}|Z_{1:t-1}) \frac{p(Z_t|X_t)p(X_t|Z_{1:t-1})}{p(Z_t|Z_{1:t-1})} \quad (4.19)$$

La densité de probabilité $p(X_{0:t-1}, Z_{1:t-1})$ est approchée par un ensemble de particules pondé-

rées $\left\{ X_{t-1}^{(j)}, \omega_{t-1}^{(j)} \right\}_{j=1}^N$. Au temps t , le poids de chaque particule est donc donné par :

$$\omega_t^{(j)} = \frac{p(X_{0:t}^{(j)} | Z_{1:t})}{\pi_t(X_{0:t}^{(j)} | Z_{1:t})} \quad (4.20)$$

Il faut aboutir à une formule récurrente de la distribution d'importance complète $\pi(X_{0:t}^{(j)} | Z_{1:t})$. On note pour cela $q(X_t | X_{t-1}, Z_t)$ la distribution d'importance séquentielle qui permet de faire évoluer les particules d'un instant au suivant. La densité complète peut alors se réécrire :

$$\pi_t(X_{0:t} | Z_{1:t}) = \pi_0(X_0) \prod_{k=1}^t q_k(X_k | X_{k-1}, Z_k) \quad (4.21)$$

Cette équation permet alors la mise à jour des poids de manière récursive :

$$\begin{aligned} \omega_t^{(j)} &= \frac{p(X_{0:t}^{(j)} | Z_{1:t})}{\pi_t(X_{0:t}^{(j)} | Z_{1:t})} \\ &= \omega_{t-1}^{(j)} \frac{p(Z_t | X_t^{(j)}) p(X_t^{(j)} | X_{t-1}^{(j)})}{p(Z_t | Z_{1:t-1}) q_t(X_t^{(j)} | X_{t-1}^{(j)}, Z_t)} \end{aligned} \quad (4.22)$$

La connaissance de $p(Z_t | Z_{1:t-1})$ est une nouvelle fois occultée par normalisation des poids. On obtient finalement la formulation récursive pour la mise à jour des poids de chaque particule :

$$\omega_t^{(j)} \propto \omega_{t-1}^{(j)} \frac{p(Z_t | X_t^{(j)}) p(X_t^{(j)} | X_{t-1}^{(j)})}{q_t(X_t^{(j)} | X_{t-1}^{(j)}, Z_t)} \quad (4.23)$$

En résumé, le filtrage particulaire repose sur deux étapes :

- la phase d'échantillonnage, lors de laquelle les trajectoires des particules dans l'espace d'état sont générées selon la loi d'importance $q_t(X_t | X_{t-1}, Z_t)$;
- la phase de correction, réalisée par le calcul des poids de chaque particule selon $p(Z_t | X_t)$.

Le principe général du filtre particulaire SIS est résumé par l'algorithme 6. La phase d'initialisation s'effectue en échantillonnant les particules selon une distribution d'importance $\pi_0(X_0)$ et en calculant leur poids selon la formule 4.16. Après évolution des particules et calcul des nouveaux poids, l'estimation de l'état se fait en utilisant l'approximation particulaire :

$$\hat{X}_{t|t} = \sum_{j=1}^N \omega_t^{(j)} X_t^{(j)} \quad (4.24)$$

L'estimation de l'état correspond au premier moment de la loi conditionnelle $p(X_t | Z_{1:t})$. On peut également calculer les moments d'ordre 2 (matrice de covariance $\hat{P}_{t|t}$) de la manière suivante :

$$\hat{P}_{t|t} = \sum_{j=1}^N \omega_t^{(j)} (X_t^{(j)} - \hat{X}_{t|t})(X_t^{(j)} - \hat{X}_{t|t})^T \quad (4.25)$$

Initialisation N : nombre de particules**pour** j de 1 à N **faire**

$$\begin{array}{|l} X_0^{(j)} \sim \pi_0(X_0) \\ \omega_0^{(j)} = \frac{p(X_0^{(j)})}{\pi_0(X_0^{(j)})} \end{array}$$

fin

$$S \leftarrow \sum_{j=1}^N \omega_0^{(j)}$$

pour j de 1 à N **faire**

$$\omega_0^{(j)} \leftarrow \frac{\omega_0^{(j)}}{S}$$

fin**Itération de l'instant t** **pour** j de 1 à N **faire**

$$\begin{array}{|l} X_t^{(j)} \sim q_t(X_t^{(j)} | X_{t-1}^{(j)}, Z_t) \\ \omega_t^{(j)} = \omega_{t-1}^{(j)} \frac{p(Z_t | X_t^{(j)}) p(X_t^{(j)} | X_{t-1}^{(j)})}{q_t(X_t^{(j)} | X_{t-1}^{(j)}, Z_t)} \end{array}$$

fin

$$S \leftarrow \sum_{j=1}^N \omega_t^{(j)}$$

pour j de 1 à N **faire**

$$\omega_t^{(j)} \leftarrow \frac{\omega_t^{(j)}}{S}$$

fin**Estimation à l'instant t**

$$\hat{X}_{t|t} = \sum_{j=1}^N \omega_t^{(j)} X_t^{(j)}$$

Algorithme 6 : Filtre particulaire SIS**4.3.3.2 Filtrage particulaire avec redistribution (SIR)**

Dans l'approche SIS, la meilleure utilisation possible des particules n'est pas assurée puisque la variance des poids augmente avec le temps. En effet, une majorité des particules se dispersent au fil du temps et seules quelques-unes (proches de l'estimation de l'état) possèdent un poids non nul, ce qui conduit à un phénomène de dégénérescence des particules. Ce phénomène dépend du choix de la distribution d'importance. Les particules pondérées ne représentent donc plus fidèlement la distribution *a posteriori*. Une procédure de redistribution statistique des particules (aussi appelée rééchantillonnage) est alors mise en place visant à dupliquer les particules de poids fort et à détruire celles de poids faible. Un indicateur définissant la qualité de l'approximation de la densité de

probabilité, à savoir le nombre de particules efficaces N_{eff} [KLW94], est défini :

$$N_{eff} = \frac{1}{\sum_{j=1}^N \left(\omega_t^{(j)}\right)^2} \quad (4.26)$$

Ce paramètre caractérise la dégénérescence des particules. Dans un fonctionnement nominal, la loi des grands nombres suppose qu'une estimation efficace est assurée par des particules de poids proches du cas équiprobable ($\sim 1/N$). Dans ce cas, $N_{eff} \rightarrow N$ et le filtre particulaire assure une utilisation optimale des particules. N_{eff} va donc être utilisé comme un indicateur de « bon fonctionnement » du filtre. Lorsque N_{eff} sera au-dessous d'un certain seuil η , on procédera à une étape de redistribution des particules. Ce filtre est connu sous le nom de filtre SIR (Sampling Importance Resampling) [Che03]. L'algorithme du filtre particulaire SIR est similaire à celui présenté en 6 : une étape de redistribution statistique est ajoutée afin de limiter la dégénérescence des particules. Différentes politiques de redistribution peuvent être mises en œuvre [BDH03, Che03, HSG06]. Par exemple, le rééchantillonnage multinomial (algorithme 7) consiste à déterminer le nouvel ensemble de particules équipondérées en effectuant N tirages avec remise parmi l'ensemble des particules avec la probabilité de choisir la particule j égale à son poids $\omega_t^{(j)}$. Deux autres techniques de rééchantillonnage sont présentées (algorithmes 8 et 9). Elles présentent l'avantage d'une différence possible entre les nombres de particules en entrée (N) et sortie (M) de l'algorithme (utilisation dans des filtres PHD).

Entrées : $\left\{ X_t^{(j)}, \omega_t^{(j)} \right\}_{j=1}^N$

Sorties : vecteur *parents* où l'indice j donne le nombre de fois où la $j^{\text{ème}}$ particule est dupliquée

$u_0 \sim U([0, 1])$; // Tirage selon la loi uniforme

pour k de 1 à N **faire**

$\tilde{u} \sim U([0, 1])$

$u_k = u_{k-1} \tilde{u}^{1/k}$

fin

$parents \leftarrow \mathbf{1}_{N \times 1}$

pour k de 1 à N **faire**

Trouver i tel que $v_i \leq u_k < v_{i+1}$

$parents(i) = parents(i) + 1$; // Copie de la particule i

fin

Algorithme 7 : Principe de rééchantillonnage « Multinomial Resampling »

Dans l'algorithme « Systematic Resampling », un vecteur de sortie permet de créer un nouvel ensemble de particules équipondérées en $1/M$. La seconde technique « Residual Resampling » est une approche partiellement déterministe où le nombre de copies d'une particule est déterminé en fonction de son poids. La méthode ne garantissant pas un nombre de répliques égal au nombre désiré de particules sortantes, un rééchantillonnage de type « Systematic » est appliqué pour créer

```

Entrées :  $\{X_t^{(j)}, \omega_t^{(j)}\}_{j=1}^N$ 
Sorties : vecteur parents où l'indice j donne le nombre de fois où la jème particule est
dupliquée
 $u \sim U(M)$  ; // Tirage selon la loi uniforme
 $S = 0$ 
pour m de 1 à N faire
|    $k = 0$ 
|    $S \leftarrow S + \omega_t^{(m)}$ 
|   tant que  $s > u$  faire
|   |    $k \leftarrow k + 1$ 
|   |    $u \leftarrow u + \frac{1}{M}$ 
|   fin
|    $parents(m) = k$  ; // nombre de répliques de la particule m
fin

```

Algorithme 8 : Principe de rééchantillonnage « Systematic Resampling »

les particules restantes.

4.3.3.3 Autres méthodes de filtrage particulaire

Comme nous venons de l'expliquer, l'étape de redistribution est indispensable au bon fonctionnement de tout filtre particulaire pour limiter le problème de dégénérescence, mais cette phase peut à son tour engendrer des effets néfastes [GSS93]. En effet, les particules de poids fort sont dupliquées en nombreuses particules filles identiques. Il y a donc regroupement des particules et ainsi un manque de diversité notamment en cas de bruit de dynamique faible. La densité *a posteriori* est ainsi mal représentée. Pour palier ce problème, d'autres techniques de rééchantillonnage ont été proposées [Che03] : la phase de rééchantillonnage du filtre RPF (« Regularized Particle Filter ») [MOL01, LWM11] s'effectue à partir d'une approximation continue de la densité *a posteriori* $p(X_t|Z_{1:t})$ par utilisation du noyau d'Epanechnikov.

La conception des filtres peut aussi être modifiée afin d'améliorer la qualité de l'approximation [CCF99, GDW⁺01, BRL⁺09] sans augmenter le nombre de particules. Le filtre particulaire ASIR (« Auxiliary Sampling Importance Resampling ») [DDFG01] se différencie du filtre SIR en générant des échantillons conditionnés par la mesure de l'instant courant. Il en résulte une plus forte robustesse aux mesures aberrantes mais peut aussi engendrer une dégradation des performances si l'approximation de $p(X_t|X_{t-1}, Z_t)$ est mauvaise. Une étape de dispersion, dite aussi régularisation, des particules peut aussi être envisagée [GSS93] par l'ajout d'un bruit d'état artificiel après la redistribution dont la variance peut soit être constante, soit dépendre de la variance estimée par le nuage de particules.

Des méthodes utilisant le théorème de Rao-Blackwell ont également été développées [DGA00, GSB07]. Ces méthodes reposent sur une décomposition de l'espace d'état en deux sous-espaces. L'un sera alors traité par un filtre particulaire et l'autre par un filtre de Kalman. La variance de

```

Entrées :  $\{X_t^{(j)}, \omega_t^{(j)}\}_{j=1}^N$ 
Sorties : vecteur parents où l'indice j donne le nombre de fois où la jème particule est
dupliquée
 $M_r = M$ 
pour m de 1 à N faire
|    $parents(m) = \lfloor \omega_t^{(m)} \cdot M \rfloor$ 
|    $\omega_t^{(m)} = \omega_t^{(m)} \cdot M - parents(m) ;$  // poids résiduel
|    $M_r = M_r - parents(m) ;$  // nombre résiduel de particules à créer
fin
si  $M_r > 0$  alors
|   pour m de 1 à N faire
|   |    $\omega_t^{(m)} = \omega_t^{(m)} / M_r$ 
|   fin
|    $parents' = \text{SystematicResampling}(N, M_r)$ 
|   pour m de 1 à N faire
|   |    $parents(m) = parents(m) + parents'(m)$ 
|   fin
fin

```

Algorithme 9 : Principe de rééchantillonnage « Residual Resampling »

l'approximation est ainsi réduite et au final moins de particules sont nécessaires pour la mise en œuvre du filtre.

4.3.3.4 Distributions d'importance

Les procédures de redistribution et de régularisation décrites permettent de maintenir un nuage homogène de particules, qui n'est ni trop dispersé, ni trop éloigné des particules de poids forts. Ces opérations perturbent le filtre et renforcent donc la nécessité de choisir judicieusement la distribution d'importance $q_t(X_t|X_{t-1}, Z_t)$. Une mauvaise loi d'importance peut conduire à une exploration des zones de l'espace d'état à faible probabilité par un nombre élevé de particules, diminuant la qualité globale de l'estimateur. Plusieurs choix de distribution d'importance sont possibles [Che03] :

- **Densité optimale :** la distribution d'importance optimale est la densité de probabilité qui minimise la variance des poids d'importance $\omega_t^{(j)}$ conditionnellement aux mesures $Z_{1:t}$ et aux états $X_{0:t-1}$. [KLW94, DdFMR00] ont montré que cette densité est :

$$q_t(X_t|X_{t-1}, Z_t) = p(X_t|X_{t-1}, Z_t) \quad (4.27)$$

Il est en général impossible d'échantillonner selon cette loi et de calculer la probabilité 4.28 pour la mise à jour des poids.

$$p(Z_t|X_{t-1}^{(j)}) = \int_{X_t} p(Z_t|X_t)p(X_t|X_{t-1}^{(j)})dX_t \quad (4.28)$$

L'objectif est alors de trouver un compromis entre facilité de programmation et optimatilité de la loi, afin de réduire la fréquence de rééchantillonnage.

- **Distribution *a priori* (ou loi de dynamique)** : il s'agit de la méthode la plus simple et la plus rapide, qui ne tient pas compte de l'observation courante :

$$q_t(X_t|X_{t-1}, Z_t) = p(X_t|X_{t-1}) \quad (4.29)$$

Il s'agit alors de générer les trajectoires des particules en appliquant simplement le modèle d'état avec un tirage de bruit pour chaque particule. L'étape de correction des poids (éq. 4.22) avant normalisation se simplifie alors simplement en :

$$\omega_t^{(j)} = \omega_t^{(j)} p(Z_t|X_t^{(j)}) \quad (4.30)$$

Cette méthode est très souvent utilisée (filtre « bootstrap ») du fait de son faible coût calculatoire. Comme elle ne tient pas compte de l'observation courante, elle est parfois non optimale et peut amener à un rééchantillonnage fréquent. Cependant, sa rapidité engendre la possibilité d'augmenter le nombre de particules du filtre et peut donc conserver une bonne approximation de la densité *a posteriori*.

- **Méthode par réjection** : cette technique consiste à échantillonner la loi $p(X_t|X_{t-1}, Z_t)$ par une méthode d'acceptation-rejet. Les N particules sont tirées suivant $p(X_t|X_{t-1})$ et acceptées uniquement si leur vraisemblance $p(Z_t|X_t^{(j)})$ est suffisante par comparaison avec un majorant de $p(Z_t|X_t)$. Cette méthode présente plusieurs inconvénients : il faut être capable de déterminer le majorant et elle est plus difficilement compatible avec des applications en temps-réel puisque le nombre de tirages nécessaires avant d'accepter une particule est inconnu *a priori*.
- **Linéarisation locale** : l'idée consiste à approcher la distribution d'importance optimale par une distribution gaussienne en linéarisant le problème autour de l'état de chaque particule et en faisant une étape de filtrage EKF ou UKF. La densité s'écrit alors :

$$q_t(X_t|X_{t-1}, Z_t) = \mathcal{N}(\hat{X}_{t|t}^{(j)}, \hat{P}_{t|t}^{(j)}) \quad (4.31)$$

$\hat{X}_{t|t}^{(j)}$ et $\hat{P}_{t|t}^{(j)}$ sont la moyenne et la matrice de covariance données par un filtre linéaire en prenant comme état initial $\hat{X}_{t-1|t-1}^{(j)} = X_{t-1}^{(j)}$ et $\hat{P}_{t-1|t-1}^{(j)} = (0)$. Cette méthode est assez efficace mais peut présenter un coût calculatoire plus élevé car il faut mettre en œuvre un filtre de Kalman pour chaque particule.

4.4 Suivi multi-cibles

L'ensemble des méthodes de filtrage présentées dans les sections précédentes peuvent être utilisées dans le cadre du suivi d'un seul objet lié à une observation Z_t présente de manière certaine à chaque instant. Le calcul de la vraisemblance $p(Z_t|X_t)$ est alors possible pour l'étape de correction

du filtre connaissant les équations de modèles. En pratique, dans un cas multi-cibles, cette philosophie ne peut être mise en place : même si l'on prend l'hypothèse d'indépendance de J objets avec la réalisation de J filtres indépendants, il faudrait disposer d'une mesure certaine de chaque objet. L'incertitude de mesure, la défaillance possible des capteurs ou la redondance de certaines observations amènent à chaque instant un ensemble de M mesures $\{Z_t\}$ composé des observations des objets mais aussi de fausses alarmes et de « clutter ». Par ailleurs, certains objets peuvent ne pas être observés (situation de non-détection). Au final, les approches de suivi développées doivent prendre en compte l'ensemble de ces phénomènes.

D'un point de vue général, le suivi multi-cibles consiste à évaluer les états $\{X_t^j\}_{j=1}^J$ de J objets dans la scène à partir de l'ensemble des M observations $\{Z_t\}_{m=1}^M$ où M est généralement différent de J . Il s'agit d'un problème d'estimation d'un système à dimension variable puisqu'il faut à la fois estimer les états des cibles, mais aussi connaître le nombre de cibles à chaque instant en générant des processus de création ou de terminaison. L'espace d'état étant continu, deux philosophies différentes ont été adoptées [BSF87, Mah03] :

- la première consiste à décomposer l'espace d'état en plusieurs sous-espaces et à considérer l'état de chaque cible individuellement dans chaque sous-espace. La problématique se résume alors à connaître quelles mesures disponibles à l'instant t entrent dans les équations de correction de l'état j . Les méthodes se basant sur un processus d'association temporelle sont les premières qui ont été proposées pour résoudre ce problème.
- La seconde approche consiste à modéliser le problème sous forme de l'estimation d'une loi multimodale. L'identification des différents modes permet *a posteriori* d'estimer l'état des cibles. Des techniques spécifiques de type Monte-Carlo [KKI05] considèrent la vraisemblance d'une mesure par rapport à la densité de probabilité conjointe de l'ensemble des cibles faisant le lien avec le filtrage PHD et ses dérivés [Mah07].

Définition du « clutter » : par analogie avec le domaine du traitement de signal radar, on définit le clutter comme l'ensemble des signaux de mesure non désirés. Par opposition au bruit de mesure, ces signaux ont la particularité de présenter une cohérence temporelle. Le clutter est par ailleurs lié à l'application traitée. Dans notre problème de détection et suivi de véhicules, seront considérés comme clutter les échos liés à l'environnement (barrière, mobilier urbain, route, ...) et les objets non désirés (piétons, ...).

4.4.1 Association de données

4.4.1.1 Motivation

Lorsque l'espace d'état est d'abord discrétisé, les approches classiques de suivi multi-cibles consistent à analyser le cas de chaque cible individuellement. La difficulté est alors d'associer les mesures aux cibles suivies. L'étape d'association est donc une étape cruciale : elle identifie à chaque instant les objets présents dans la scène et une erreur d'association se propage sur l'estimation des trajectoires des objets (dénommées pistes). L'exploitation des informations de l'instant précédent se

fait par une étape de prédiction afin de prévoir les mesures à l'instant courant et d'en assurer l'association avec les données disponibles. L'étape de filtrage aura lieu uniquement si une association a été réalisée. L'objectif de l'étape d'association est donc de sélectionner les observations avec lesquelles les états des cibles seront corrigés et par conséquent augmenter la précision de l'estimation.

Afin de garantir une association efficace entre les mesures des objets et les objets prédits à partir des informations de l'état précédent, il convient de définir une région de validité (« gating ») autour de la position prédite $\hat{Z}_{t|t-1}^j$ d'une piste j . Ceci permet d'identifier un ensemble de mesures par lesquelles l'état X_t^j est potentiellement décrit. Ce fenêtrage statistique consiste à délimiter un volume V_j de l'espace d'observation où la mesure de la cible a une forte probabilité P_G de se trouver. Pour une piste j considérée, cela conduit à réaliser un test d'hypothèses (test du Khi-Deux) sur chaque mesure de l'instant courant de la manière suivante :

$$\begin{cases} d_{mj} = (Z_t^m - \hat{Z}_{t|t-1}^j) S_{mj}^{-1} (Z_t^m - \hat{Z}_{t|t-1}^j)^T \leq \gamma & (H_1) \\ d_{mj} = (Z_t^m - \hat{Z}_{t|t-1}^j) S_{mj}^{-1} (Z_t^m - \hat{Z}_{t|t-1}^j)^T > \gamma & (H_0) \end{cases} \quad (4.32)$$

- d_{mj} : distance entre une observation m et une piste j
- γ : seuil fixé en lien avec la dimension de l'espace d'observation
- S_{mj} : matrice d'innovation apportée par une observation m pour une piste j

Si (H_1) est vérifiée alors la mesure m est associée à la piste j (elle appartient à sa région de validité), sinon la mesure est rejetée. A la sortie de ce fenêtrage statistique, 3 situations peuvent se produire :

- la région de validité de la piste j inclut une unique observation ;
- plusieurs mesures sont localisées dans la région de validité d'une piste ;
- au moins une observation appartient à plusieurs régions de validité.

À partir de ces situations, différentes techniques ont alors été développées afin de procéder à la mise à jour de chaque piste :

- les premières se ramènent à un suivi mono-objet en partant du postulat qu'une seule mesure doit être associée à une piste : la méthode du Plus Proche Voisin (« Nearest Neighbor » NN) [Bla86, BSF87] sélectionne l'observation dont la distance est la plus faible à la piste j étudiée, la métrique employée étant le plus souvent la distance de Mahalanobis qui permet de prendre en compte les erreurs de prédiction sur la mesure prédite et sur les observations courantes. Bien que simple à mettre en oeuvre, les performances se dégradent significativement en cas de fausses alarmes et de cibles proches. La méthode d'association probabiliste de données (« Probabilistic Data Association » PDA) [BSF87] permet de résoudre ce problème en intégrant l'ensemble des observations candidates à l'association, ce qui implique une reformulation du filtre. La mise à jour de X_t^j se fait grâce à la vraisemblance construite à partir d'une somme pondérée des vraisemblances avec des probabilités d'association. Cette méthode, qui donne de bons résultats en suivi mono-objet [BSL95, VGP05], nécessite l'existence *a priori* de la piste et ne possède pas de module d'initialisation automatique de pistes en cas d'apparition.

- les méthodes considérant l'ensemble des associations possibles fournissent un cadre de travail plus complet. Nous détaillons dans la suite ces méthodes, connues sous le nom de « Multiple Hypothesis Tracking » (MHT) et de filtre « Joint Probabilistic Data Association » (JPDA).

4.4.1.2 La méthode MHT

La méthode Multiple Hypothesis Tracking (MHT) a été formulée par [Rei79] puis ensuite adaptée pour différentes applications [Bla86, CH96]. Il s'agit à l'instant d'estimation t de considérer l'ensemble des hypothèses d'association sachant les mesures disponibles $\{Z_t\}$ en considérant uniquement trois situations pour chaque mesure Z_t^m :

- elle constitue une fausse alarme
- elle appartient à une piste existante
- elle est à l'origine d'une nouvelle piste.

Chaque probabilité *a posteriori* des hypothèses d'association est alors évaluée récursivement en tenant compte des fausses alarmes, des non détections et de la création de nouvelles pistes. Afin d'éviter l'explosion combinatoire liée au calcul des différentes hypothèses, l'objectif est de ne garder que les hypothèses les plus probables. Le point fort de la méthode MHT est que le nombre de cibles n'est pas connu *a priori* et permet une initialisation automatique des nouvelles pistes.

Le point central de la méthode MHT est la formation d'un arbre d'hypothèses dans lequel chaque segment liant deux noeuds de l'arbre représente une hypothèse de présence de piste et sa position à l'instant t . Chaque noeud représente l'hypothèse que la mesure m provienne de la piste j . Pour chaque mesure, au moins deux noeuds de l'arbre sont construits.




FIGURE 4.2 – Exemple illustratif pour la méthode MHT

Les figures 4.2 et 4.3 illustrent cette méthode MHT dans le cas où 2 pistes existent à l'instant $(t-1)$ (indexées 1 et 2) et 3 mesures $\{Z_t^1, Z_t^2, Z_t^3\}$ sont disponibles. Les mesures Z_t^1 et Z_t^2 peuvent être associées à la piste 1, et les mesures Z_t^2 et Z_t^3 à la piste 2. L'arborescence construite tient compte du fait qu'une mesure ne peut être associée à deux pistes dans le même scénario d'association. Par




FIGURE 4.3 – Arbre issu de la méthode MHT pour le scénario choisi

exemple, la mesure Z_t^1 peut être soit une fausse alarme, soit la continuité de la piste 1 ou encore le début d'une nouvelle piste indexée par 3. On itère le processus pour les autres mesures. 30 hypothèses sont alors construites à l'instant t . L'arbre des différents scénarios d'association est alors étendu à l'instant suivant, de nouvelles hypothèses sont élaborées et le processus est ainsi construit récursivement.

Dans ce cadre, le nombre d'hypothèses suit une croissance exponentielle et le formalisme initial ne peut être en pratique implémenté. Différentes méthodes ont donc été développées pour regrouper le nombre d'hypothèses et éliminer celles à faible probabilité [Bla86, BSF87]. Deux approches principales sont développées : l'une est orientée hypothèse HOMHT [Rei79, CH96] (« Hypothesis Oriented MHT ») et l'autre est orientée piste TOMHT (« Track Oriented MHT ») [BP99, BSBF07]. Cette dernière serait adéquate pour notre type d'application. L'avantage apporté par une gestion automatique des pistes permet d'appliquer la méthode MHT dans de nombreux domaines où le suivi d'objets est indispensable [MVV08, LCB12] et permet de développer d'autres approches [CWS⁺11, HTK⁺11].

4.4.1.3 Méthode d'association probabiliste conjointe de données (JPDA)

4.4.1.3.1 Présentation

Le filtre JPDA est une extension du filtre PDA et trouve sa justification dans le fait que l'étape de filtrage ne peut se dérouler indépendamment pour chaque cible en raison de l'incertitude sur l'association de données. La méthode est largement utilisée dans les applications de suivi [Jid08, LJNW09, SSGW11] ou de vision [PLWG10] par exemple. Elle est un cas particulier de la méthode

MHT qui permet de minimiser le coût de construction et le calcul des probabilités des hypothèses d'association. La méthode, qui considère que plusieurs mesures peuvent être associées à une cible, est donc plus adaptée à la gestion des fausses alarmes.

Les méthodes probabilistes d'association de données telles que le JPDA se basent sur des hypothèses essentielles :

- à l'instant courant, le nombre de cibles J est connu ;
- une cible ne peut être générée qu'à partir d'une seule mesure ;
- une mesure ne peut provenir que d'une seule cible (sinon c'est une fausse alarme).

Cette méthode traite le cas de chevauchement entre différentes régions de validité des pistes (fig. 4.4) et dans lesquelles se trouvent des observations communes. Ces observations peuvent donc représenter n'importe quelle piste et un regroupement des pistes concernées est effectué. Un ensemble




FIGURE 4.4 – Exemple illustratif pour la méthode JPDA

d'hypothèses d'association est construit selon des règles définies : une mesure n'est à l'origine que d'une seule piste et une piste n'est associée qu'à une seule mesure, excepté pour l'événement « l'observation m de la région de validité n'est pas à l'origine de la piste » pour prendre en considération les fausses alarmes. La probabilité de chaque hypothèse est déterminée par multiplication des probabilités d'association qui font l'hypothèse, et la probabilité d'association pour une piste est obtenue par la somme des probabilités de toutes les hypothèses auxquelles elle appartient. Cette probabilité est directement intégrée dans les équations de mise à jour de l'état de la piste j [VGP05] après la phase de prédiction (éq. 4.4) faite indépendamment pour chaque cible :

$$p(Z_t | X_t^j) = \beta^0 + \sum_{m=1}^M \beta^m p(Z_t^m | X_t^j) \text{ avec } M \text{ le nombre de mesures} \quad (4.33)$$

β^m définit la probabilité *a posteriori* que la mesure m soit à l'origine de la piste j et β^0 est la probabilité que la piste soit non détectée. Il s'agit de calculer ces probabilités d'association.

4.4.1.3.2 Regroupement de pistes

La méthode JPDA est ici présentée dans un cadre général [VGP05]. En pratique, un regroupement des pistes est effectué afin de réduire le coût calculatoire. Ce « clustering » permet de ne considérer que les événements conjoints réalisables sous couvert des hypothèses de départ. Tout d'abord, toutes les associations possibles sont testées selon la procédure décrite en 4.32. Une matrice d'association $\Phi = (\phi_{mj})$ récapitulative est alors construite avec :

$$\phi_{mj} = \begin{cases} 1 & \text{si } d_{mj} \leq \gamma \\ 0 & \text{sinon} \end{cases} \quad (4.34)$$

avec $m \in [1, M]$ et $j \in [0, J]$. L'indice $j = 0$ signifie « aucune piste », *i.e.* chaque mesure peut être une fausse alarme, et donc la première colonne de la matrice Φ est constituée de 1. À partir de cette matrice, des groupes sont formés lorsqu'une mesure se trouve dans plusieurs régions de validité. On associe à chaque association une probabilité P_G (« gate probability ») qui est la probabilité d'avoir l'observation Z_t^m dans la région de validité V_t^j de la cible j :

$$P_G = p(\{Z_t^m \in V_t^j\}) \quad (4.35)$$

Cela signifie que plusieurs 1 dans une colonne de la matrice Φ (sauf la première colonne) impliquent un regroupement des cibles et observations concernées. Si l'on prend l'exemple de la figure 4.4, la matrice d'association est :

$$\Phi = \left. \begin{array}{c} \overbrace{\begin{matrix} 0 & 1 & 2 & 3 \\ \begin{pmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \end{pmatrix} \\ 1 \\ 2 \\ 3 \\ 4 \end{matrix}}^{j : \text{pistes}} \right\} m : \text{observations} \quad (4.36)$$

Les pistes 1 et 2 ont l'observation 2 en commun : elles sont alors regroupées dans un unique cluster (ainsi que toutes les observations associées à ces deux pistes) et la piste 3 est dans un second groupe. Nous considérons dans la suite de la formulation théorique de la méthode que l'ensemble des informations font partie d'un unique cluster. Si plusieurs groupes sont présents, le processus est répété en prenant en compte les cardinalités des regroupements effectués.

4.4.1.3.3 Probabilité d'association conjointe

L'objectif est le calcul des probabilités β^m (pour chaque cible j). On introduit alors des variables d'association [VGP05] pour ne pas alourdir les notations ¹ :

1. la notation sur l'instant courant t est volontairement écartée sauf en cas de confusion

- l'association (cible \rightarrow observation) est représentée par l'ensemble $\tilde{\theta} = \{\tilde{\theta}_1, \dots, \tilde{\theta}_J\}$ avec :

$$\tilde{\theta}_j = \begin{cases} 0 & \text{si la } j^{\text{ème}} \text{ cible n'est pas détectée} \\ m & \text{si la } j^{\text{ème}} \text{ cible a généré la mesure } m \end{cases} \quad (4.37)$$

- l'association (observation \rightarrow cible) est représentée par l'ensemble $\theta = \{\theta_1, \dots, \theta_M\}$ avec :

$$\theta_m = \begin{cases} 0 & \text{si la } m^{\text{ème}} \text{ mesure n'est pas associée} \\ j & \text{si la } m^{\text{ème}} \text{ mesure est à l'origine de la piste } j \end{cases} \quad (4.38)$$

Ces deux notations sont équivalentes mais présentent l'intérêt de simplifier les équations en passant de l'une à l'autre.

- des ensembles regroupant l'ensemble des associations pour chaque cible et mesure sont construits en utilisant la matrice Φ :

$$\tilde{\Theta} = \{\tilde{\Theta}_1, \dots, \tilde{\Theta}_J\} \text{ avec } \tilde{\Theta}_j = \{m | \phi_{mj} = 1\} \cup \{0\} \quad \forall j \in [1, J] \quad (4.39)$$

$$\Theta = \{\Theta_1, \dots, \Theta_M\} \text{ avec } \Theta_m = \{j | \phi_{mj} = 1\} \cup \{0\} \quad \forall m \in [1, M] \quad (4.40)$$

- M_c désigne le nombre de mesures liées au clutter qui pourront être à l'origine de nouvelles pistes à l'instant suivant : $M_c = \text{Card}(\theta_m \neq 0)$. M_a est le nombre de mesures qui représentent des cibles : $M_a = M - M_c$.

Avec ces notations, la probabilité d'association β^m s'écrit :

$$\beta^m = p(\tilde{\theta}_j = m | Z_{1:t}) \quad (4.41)$$

Afin de la calculer, un ensemble d'hypothèses d'association \mathcal{H} est construit en respectant les règles décrites en 4.4.1.3.1 à partir des ensemble $\tilde{\Theta}$ et Θ . Pour chaque hypothèse H_k , une mesure est associée à une seule piste, et une cible est soit associée à une seule mesure, soit non détectée. Si une mesure n'est jamais associée, il s'agit d'une mesure liée au clutter.

Si on reprend l'exemple 4.4 en ne considérant que les données du groupe 1, l'ensemble des événements réalisables (pouvant être déduits de la matrice Φ de départ) sont listés :

Hyp.	cible 1	cible 2
0	0	0
1	0	2
2	0	3
3	1	0
4	1	2
5	1	3
6	2	0
7	2	3

TABLE 4.1 – Ensemble des événements réalisables pour le groupe 1 de l'exemple 4.4

Il est alors possible de calculer la probabilité d'association en sommant les probabilités pour lesquelles l'événement $\tilde{\theta}_j = m$ se réalise effectivement :

$$\beta^m = \sum_{\tilde{\theta} \in \mathcal{H}|\tilde{\theta}_j=m} p(\tilde{\theta}|Z_{1:t}) \quad (4.42)$$

$p(\tilde{\theta}|Z_{1:t})$ est la probabilité d'association conjointe *a posteriori* qu'il faut déterminer pour chaque événement réalisable (relativement à la cible j). La règle de Bayes nous permet de développer :

$$p(\tilde{\theta}|Z_{1:t}) = \frac{p(Z_t|Z_{1:t-1}, \tilde{\theta})p(Z_{1:t-1}, \tilde{\theta})}{p(Z_{1:t})} \propto \underbrace{p(Z_t|Z_{1:t-1}, \tilde{\theta})}_{\textcircled{1}} \underbrace{p(\tilde{\theta})}_{\textcircled{2}} \quad (4.43)$$

$p(Z_{1:t})$ étant une constante de normalisation, il n'est pas nécessaire de la connaître explicitement et nous supposons que le vecteur $\tilde{\theta}$ est indépendant des mesures précédentes. Le calcul des densités de probabilités $\textcircled{1}$ et $\textcircled{2}$ est détaillé.

$\textcircled{1}$ $p(Z_t|Z_{1:t-1}, \tilde{\theta})$: il s'agit de la densité conjointe des probabilités des M_a observations validées conditionnée par $\tilde{\theta}$. Toutes les régions de validité des pistes d'un cluster participent maintenant à la région entière de surveillance, et donc $P_G = 1$. La densité conjointe est définie par :

$$p(Z_t|Z_{1:t-1}, \tilde{\theta}) = \prod_{m=1}^M p(Z^m|\tilde{\theta}_j, Z_{1:t-1}) \quad (4.44)$$

La densité de probabilité d'une observation Z^m est donnée par :

$$p(Z^m|\tilde{\theta}_j, Z_{1:t-1}) = \begin{cases} p^j(Z^m|Z_{1:t-1}) & \text{si } \text{Card}(\Theta_m - \{0\}) \neq 0 \\ V^{-1} & \text{si la mesure } m \text{ n'est pas associée} \end{cases} \quad (4.45)$$

Une observation clutter a une densité uniforme de valeur V^{-1} où V est le volume de la région entière de surveillance approximé par la somme des volumes de régions de validité, les intersections de volumes n'étant pas prises en compte [Bla86]. $p^j(Z^m|Z_{1:t-1})$ est la vraisemblance prédite pour la cible j . Celle-ci se détermine dans un cas général par :

$$p^j(Z^m|Z_{1:t-1}) = \int_{X_t^j} p(Z_t^m|X_t^j) p^j(X_t^j|Z_{1:t-1}) dX_t^j \quad (4.46)$$

Soit \mathcal{I} l'ensemble des mesures générées par les cibles, *i.e.* $\mathcal{I} = \{m \in [1, M] | \Theta_m \neq \{0\}\}$. L'équation 4.44 devient :

$$p(Z^m|\tilde{\theta}_j, Z_{1:t-1}) = V^{-Mc} \prod_{m \in \mathcal{I}} p^j(Z^m|Z_{1:t-1}) \quad (4.47)$$

$\textcircled{2}$ $p(\tilde{\theta})$: il s'agit de la densité de probabilité d'association conjointe *a priori* et elle est indépendante de l'état et des hypothèses d'association précédentes dans un cadre bayésien. Celle-ci est

définie par [Fre99] :

$$p(\tilde{\theta}) = p(\tilde{\theta}|M_c, M_a) p(M_c) p(M_a) \quad (4.48)$$

$$\begin{cases} p(\tilde{\theta}|M_c, M_a) &= N_H^{-1} \\ p(M_c) &= \frac{\lambda_c^{M_a} e^{-\lambda_c}}{M_a!} \\ p(M_a) &= \binom{J}{M_a} P_D^{M_a} (1 - P_D)^{J - M_a} \end{cases} \quad (4.49)$$

N_H est le nombre d'hypothèses dans lesquelles le même ensemble des pistes a été détecté. Il est obtenu par la fonction de permutation [FBSS83] :

$$N_H = \binom{J}{M_a} \frac{M!}{(M - M_a)!} \quad (4.50)$$

Elle consiste à choisir un ensemble de M_a éléments parmi J multiplié par le nombre d'associations possibles entre les M_a mesures associées et les M mesures. Le nombre de mesures liées au clutter M_c est supposé suivre une loi de Poisson de paramètre λ_c qu'on peut définir en terme de densité spatiale de clutter μ_c . On a donc $\lambda_c = \mu_c V$. La densité *a priori* pour le nombre de détections s'obtient en considérant les $\binom{J}{M_a}$ façons possibles de grouper M_a détections parmi les J cibles sous les hypothèses de départ. Toutes les cibles sont supposées posséder la même probabilité de détection P_D mais il est possible dans le raisonnement de la rendre variable.

Une factorisation de la densité d'association conjointe est proposée dans [VGP05] en utilisant les notations d'association (cible \rightarrow observation) et aboutit à l'expression :

$$p(\tilde{\theta}) = p(M_c) \prod_{j=1}^J p(\tilde{\theta}_j | \tilde{\theta}_{1:j-1}) \quad (4.51)$$

On note M_m le nombre de mesures non assignées sachant celles déjà associées parmi les $(j - 1)$ èmes premières cibles :

$$M_m = M - \text{Card}(\{l | \tilde{\theta}_l \neq 0, l \in \llbracket 1, j - 1 \rrbracket\}) \quad (4.52)$$

Dans l'équation 4.51, les densités d'associations propres à chaque cible sont obtenues par :

$$p(\tilde{\theta}_j = m | \tilde{\theta}_{1:j-1}) \propto \begin{cases} 1 - P_D & \text{si } m = 0 \\ 0 & \text{si } m > 0 \text{ et } m \in \{\tilde{\Theta}_1, \dots, \tilde{\Theta}_{j-1}\} \\ \frac{P_D}{M_m} & \text{sinon} \end{cases} \quad (4.53)$$

Après simplification, la probabilité d'association conjointe *a posteriori* $p(\tilde{\theta} | Z_{1:t})$ devient donc :

$$p(\tilde{\theta} | Z_{1:t}) \propto \frac{\lambda_c}{M_a!} e^{-\lambda_c V^{-Ma}} \prod_{m \notin \mathcal{I}} (1 - P_D) \prod_{m \in \mathcal{I}} P_D p^{\theta_m}(Z^m | Z_{1:t-1}) \quad (4.54)$$

4.4.1.3.4 Probabilités d'association de données

La probabilité d'association β^m pour une cible j donnée est obtenue en sommant la probabilité de toutes les hypothèses dans lesquelles cette condition est produite :

$$\begin{aligned}\beta^m &= \sum_{\theta_m=j} p(\tilde{\theta} | Z_{1:t}) \\ \beta^0 &= 1 - \sum_{m=1}^M \beta^m\end{aligned}\tag{4.55}$$

L'estimation de l'état de la piste j se calcule alors par les équations de correction du filtre utilisé en utilisant la pseudo-vraisemblance considérée.

4.4.1.3.5 Implémentation

La méthode générale décrite ci-dessus s'implémente selon les spécifications de l'application : des modèles linéaires et gaussiens permettent d'obtenir des solutions analytiques au calcul des densités de probabilités [Bla86, BSF87] et de simplifier grandement les équations. Dans le cas où ces conditions ne sont pas remplies, le filtrage particulière fournit un cadre de résolution en pondérant chaque particule avec la pseudo-vraisemblance construite [SBFC01, VGP05, GM07]. [HCP02] propose une méthode dans laquelle la distribution des hypothèses d'association est approchée en utilisant des échantillons de Gibbs [GG84] qui permettent aussi d'automatiser le processus de création / arrêt de pistes.

La structure d'un filtre JPDA peut être décrite comme suit :

1. les états prédits pour chaque cible sont calculés en utilisant les équations de modèle et les états estimés précédents. Les mesures prédites sont alors déduites à partir du modèle d'observation.
2. Après la détermination des régions de validité, les mesures à l'instant t sont associées aux cibles. Un regroupement des pistes aux observations communes est alors appliqué afin de réduire le nombre d'hypothèses d'association.
3. Pour chaque groupe, l'ensemble des hypothèses d'association (cible \rightarrow observation) est construit basé sur les hypothèses « une cible n'est représenté que par au plus une mesure » et « une mesure est soit une fausse alarme, soit représentative d'une seule cible ».
4. La probabilité de chaque hypothèse d'association est calculée, et la probabilité d'association β^m (cible $j \rightarrow$ observation m) est obtenue en additionnant les probabilités d'hypothèses d'association pour lesquelles l'événement se réalise.
5. Enfin, la pseudo vraisemblance de la cible j est construite par somme des vraisemblances pondérées par les probabilités d'association β^m et permet de corriger l'état de la cible j .

Le détail de l'algorithme sera présenté dans le chapitre suivant puisqu'il a été mis en œuvre pour le suivi de véhicules à partir de données télémétriques.

4.4.1.3.6 Discussion

Bien que le JPDA permette de réduire le nombre d'hypothèses d'association, il souffre d'inconvénients majeurs :

- l'hypothèse restrictive d'un nombre connu et invariant de cibles à l'instant t empêche un processus de création de pistes. Le filtre Joint Integrated Probabilistic Data Association (JIPDA) [ME04] propose une extension pour appréhender le cas d'un nombre variable de cibles, en donnant une meilleure approximation du nombre de fausses alarmes dans un cluster. [SSGW11] améliore les performances du filtre en cas de cibles très proches qui permettent d'obtenir des résultats similaires à ceux résultant de méthodes où le nombre de cibles est variable (PHD).
- il est de plus difficile avec un filtre JPDA de maintenir la continuité des pistes en cas de non-détections ou fausses alarmes. Selon les applications spécifiques d'utilisation, il est néanmoins possible d'imaginer des techniques de conservation de trajectoires et de création de pistes.

La simplicité de mise en oeuvre ainsi que les bons résultats tant que le cluster n'est pas de cardinalité trop grande et que le nombre de fausses alarmes est faible font que cet algorithme est très populaire pour résoudre des problèmes de suivi multi-cibles.

4.4.2 L'approche PHD

4.4.2.1 Principe

La problématique du suivi multi-cibles est d'estimer l'état des cibles ainsi que leur nombre à chaque instant. Si le nombre de cibles est constant, la méthode JPDA fournit un cadre de résolution efficace. Dans le cas contraire, la méthode MHT permet une gestion des pistes plus fine en automatisant les processus de création et terminaison. Dans les deux cas, les incertitudes de détection et le clutter peuvent perturber l'étape d'estimation. Les méthodes d'association employées sont aussi à l'origine de perturbations et engendrent une augmentation exponentielle de la taille de l'espace d'état en rapport avec le nombre de cibles.

Pour éviter ce problème, Mahler a introduit un formalisme de détection et de suivi multi-cibles basé sur la considération de l'ensemble des états et des mesures comme deux ensembles finis aléatoires (RFS : « Random Finite Set ») : le filtrage « Probability Hypothesis Density » (PHD) [Mah03]. Le concept est de propager le premier moment de la distribution *a posteriori* liée au problème multi-cibles, dénommé PHD, dont l'intégrale sur un sous-espace de l'espace d'état permet d'obtenir une estimation du nombre d'objets dans ce sous-espace. L'extraction des maxima locaux de cette distribution permet finalement d'obtenir l'estimation des états des objets.

Le filtrage PHD jouit d'une popularité grandissante ces dernières années, il est utilisé dans de nombreux domaines applicatifs tels que le suivi multi-cibles [Pac11], la vision [PHO07], SLAM [MVAV11] ou des systèmes basés sur des capteurs lidar [GLO12] ou sonar [CRPB07].

4.4.2.2 Filtrage bayésien multi-cibles

Un RFS est un ensemble fini de variables aléatoires continues dont la cardinalité est elle-même une variable aléatoire. La théorie statistique des ensembles finis (FISST) permet de fournir les outils pour formaliser le suivi multi-cibles dans un cadre bayésien [Mah97].

L'ensemble des cibles et des observations à l'instant t est respectivement représenté par les RFS \mathcal{X}_t

et \mathcal{Z}_t . Le RFS de l'état à l'instant t peut être décrit comme la composition des cibles à l'instant $t-1$ et des nouvelles cibles à l'instant t :

$$\mathcal{X}_t = \left(\bigcup_{X_{t-1} \in \mathcal{X}_{t-1}} \Phi(X_{t-1}, W_{t-1}) \right) \cup (B(X(t))) \quad (4.56)$$

- $\Phi(\cdot)$: fonction de transition mono-cible
- W_{t-1} : bruit du modèle d'état multi-cibles
- $B(X(t))$: ensemble des nouvelles cibles à l'instant t (spontanées ou dupliquées)

Le RFS $\Phi(X_{t-1}, W_{t-1})$ peut prendre la valeur $\{X_t\}$ avec une probabilité $p_s(X_t)$ (probabilité de survie) ou \emptyset avec la probabilité $(1 - p_s(X_t))$. L'évolution d'une cible à partir de son état précédent est modélisée par la fonction de transition markovienne mono-cible $f_{t|t-1}(\cdot | X_{t-1})$.

En incluant la vraisemblance, l'incertitude de détection du capteur et le clutter, le RFS des observations peut être modélisé par :

$$\mathcal{Z}_t = \left(\bigcup_{X_t \in \mathcal{X}_t} \tilde{\mathcal{Z}}(X_t) \right) \cup (K_t) \quad (4.57)$$

- $\tilde{\mathcal{Z}}(X_t)$: RFS des mesures issues des cibles X_t
- K_t : RFS des fausses alarmes (clutter)

Pour $X_t \in \mathcal{X}_t$, $\tilde{\mathcal{Z}}(X_t)$ contribue à la mesure $\{Z_t\}$ avec une probabilité de détection $p_D(X_t)$ ou \emptyset avec la probabilité complémentaire. La génération de la mesure Z_t à partir de X_t est modélisée par la fonction d'observation $h_t(\cdot | X_t)$.

Les incertitudes sur l'évolution de \mathcal{X}_t et la génération de \mathcal{Z}_t peuvent respectivement être caractérisées par la densité de probabilité de transition multi-cibles $p(\mathcal{X}_t | \mathcal{X}_{t-1})$ et la vraisemblance de mesure multi-cibles $p(\mathcal{Z}_t | \mathcal{X}_t)$. Cette densité inclut tous les aspects du mouvement multi-cibles : nombre, dynamique individuelle, naissance, terminaison, dédoublement et interactions de cibles. De manière similaire, la vraisemblance inclut toutes les caractéristiques du capteur telles que la vraisemblance de mesure, la probabilité de détection et les modèles de clutter. L'objet du filtrage bayésien multi-cibles est de calculer la densité *a posteriori* $p_t(\cdot | \mathcal{Z}_{1:t})$ à partir de la connaissance supposée de la loi *a priori* $p_{t-1}(\cdot | \mathcal{Z}_{1:t-1})$.

En pratique, il est difficile de calculer une telle densité. Les outils FISST permettent la construction d'un filtre multi-cibles de manière analogue à celle du suivi mono-cible. Cette construction a lieu en deux étapes classiques de prédiction et de correction :

- grâce à une mesure d'intégration judicieusement choisie sur le RFS [VSD05], la densité de probabilité prédite à partir de celle de l'instant $(t-1)$ est obtenue par :

$$p_{t-1}(\mathcal{X}_t | \mathcal{Z}_{1:t-1}) = \int_{\mathcal{X}_{t-1}} f_{t|t-1}(\mathcal{X}_t | \mathcal{X}_{t-1}) p_{t-1}(\mathcal{X}_{t-1} | \mathcal{Z}_{1:t-1}) d\mathcal{X}_{t-1} \quad (4.58)$$

– la densité est ensuite mise à jour en utilisant le RFS d'observation :

$$p_t(\mathcal{X}_t | \mathcal{Z}_{1:t}) = \frac{h_t(\mathcal{Z}_t | \mathcal{X}_t) p_{t-1}(\mathcal{X}_t | \mathcal{Z}_{1:t-1})}{\int_{\mathcal{X}} h_t(\mathcal{Z}_t | \mathcal{X}) p_{t-1}(\mathcal{X} | \mathcal{Z}_{1:t-1}) d\mathcal{X}} \quad (4.59)$$

Il est impossible de calculer analytiquement les intégrales des équations 4.58 et 4.59, sauf dans des cas très restrictifs [SW03]. Tout comme les méthodes d'approximation existantes pour le filtrage bayésien optimal mono-cible, une approximation de ce filtre, appelée PHD, a été proposée par Mahler. La densité multi-cibles est approchée par son premier moment et propagée dans le filtre.

4.4.2.3 Le filtre PHD (ou fonction intensité)

D'un point de vue théorique, le filtre PHD n'est pas optimal mais représente une solution exploitable du problème de filtrage multi-cibles. La fonction intensité, ou PHD, est le premier moment de la densité de probabilité multi-cibles définie sur \mathcal{X} :

$$D_{t|t}(X | \mathcal{Z}_{1:t}) = \int_{\mathcal{X}} \delta_{\mathcal{X}}(X) f_{t|t-1}(\mathcal{X} | \mathcal{Z}_{1:t-1}) d\mathcal{X} \quad (4.60)$$

où δ est la mesure Dirac. Le PHD est donc une fonction non négative qui a la propriété suivante sur n'importe quel sous-espace $S_0 \subseteq S^{\mathcal{X}}$ avec une probabilité de distribution \mathcal{P} :

$$\int_{S_0} D_t(X) dX = \int |\mathcal{X} \cap S_0| \mathcal{P}(d\mathcal{X}) \quad (4.61)$$

$|\cdot|$ est la cardinalité du RFS \mathcal{X} . Ainsi, l'intégrale sur un sous-espace S_0 permet d'obtenir une estimation du nombre d'éléments du RFS \mathcal{X} présents dans cet espace. Dans le contexte de suivi multi-cibles, cette valeur est égale au nombre d'objets présents à l'instant t . Les modes de la fonction intensité sont alors extraits afin d'estimer les états des cibles.

Le filtre PHD se décompose de nouveau en deux étapes [Mah03] :

– une étape de prédiction qui permet de calculer la fonction intensité $D_{t|t-1}$ à partir de la fonction intensité *a posteriori* de l'instant précédent $D_{t-1|t-1}$:

$$D_{t|t-1}(X | \mathcal{Z}_{1:t-1}) = \int_{\Omega} [p_s(\Omega) f_{t|t-1}(X | \Omega) + \beta_{t|t-1}^s(X | \Omega)] D_{t-1|t-1}(\Omega | \mathcal{Z}_{1:t-1}) d\Omega + \beta_t^b(X) \quad (4.62)$$

- Ω : état précédent
- $p_s(\cdot)$: probabilité de survie d'une piste de l'instant $t-1$ à l'instant t
- $f_{t|t-1}(\cdot | \cdot)$: modèle dynamique de chaque cible
- $\beta_{t|t-1}^s(\cdot | \Omega)$: intensité des cibles RFS dupliquées
- $\beta_t^b(X)$: intensité des nouvelles cibles

– la mise à jour de la fonction intensité s’obtient par :

$$D_{t|t}(X|\mathcal{Z}_{1:t}) = [1 - p_D(X)] D_{t|t-1}(X|\mathcal{Z}_{1:t-1}) + \sum_{Z \in \mathcal{Z}_t} \frac{p_D(X) L_Z(X) D_{t|t-1}(X|\mathcal{Z}_{1:t-1})}{\kappa(Z) + \int_{\Omega} p_D(\Omega) L_Z(\Omega) D_{t|t-1}(X|\mathcal{Z}_{1:t-1}) d\Omega} \quad (4.63)$$

$L_Z(X)$: fonction de vraisemblance du capteur

$\kappa(\cdot)$: fonction d’intensité avec $\kappa(\cdot) = \lambda c(\cdot)$ où

$c(\cdot)$ est la densité de probabilité du clutter (généralement uniforme) et λ , le paramètre de la loi de Poisson pour la cardinalité de la fonction κ

Les cibles évoluent et génèrent des observations de manière indépendante. La distribution du nombre de fausses alarmes suit une loi de Poisson [BSF87]. L’hypothèse supplémentaire selon laquelle le RFS multi-cibles est poissonnien est indispensable à la mise à jour des équations du PHD car elle permet à la fonction intensité de caractériser entièrement le RFS.

4.4.2.4 Implémentations du filtre PHD

L’utilisation d’intégrales multi-dimensionnelles implique qu’il n’existe pas de solution analytique pour la représentation de la fonction intensité *a posteriori*. Si les équations de dynamique et d’observation des objets sont linéaires, le bruit associé gaussien et la densité de probabilité des pistes naissantes gaussienne, alors une solution analytique a été proposée dans [VM05]. Celle-ci est basée sur l’utilisation de mélanges de gaussiennes (filtre GM-PHD) avec une perspective sur le traitement de problèmes non-linéaires. La convergence de ce filtre est démontrée dans [CV07]. Une approche particulière, dénommée « SMC-PHD filter », a été proposée par [VSD03, VSD05, RCV10] dans un cadre plus général. La fonction intensité $D_{t|t}$ *a posteriori* est approchée par un nuage pondéré de particules qui sont propagées via les équations récursives 4.62 et 4.63. Le nombre de particules utilisées est lié au nombre estimé de cibles à chaque instant, ce qui entraîne une modification des processus de redistribution statistique précédemment décrits. La convergence du filtre SMC-PHD est montrée dans [VSD05]. Ce filtre atteint sa limite quand la vraisemblance du RFS des observations est inconnue ou le bruit de mesure est très faible. [PV07] propose un filtre PHD basé sur un noyau de convolution pour résoudre ce problème.

Le filtre PHD fournit une approximation de la fonction intensité *a posteriori*, mais des techniques additionnelles doivent donc être utilisées pour aboutir à l’estimation des états. Cette estimation s’effectue en extrayant les modes de la fonction intensité estimée par une étape de clustering. Parmi les méthodes généralement utilisées, on peut citer l’algorithme « Expectation-Maximization » (EM) [CRPB07, SW03] ou le « k -means » [VSD03, VSD05] dans lequel le nombre de clusters à déterminer est donné par une approximation entière du nombre de cibles attendues. Le centre de chaque cluster représente un maximum local de la fonction intensité et donc l’état estimé de la cible. C’est cette solution que nous utiliserons dans la suite du manuscrit, puisque [Cla06] montre en particulier

que l'algorithme « k -means » est plus performant et moins coûteux que EM. Des solutions alternatives peuvent être trouvées dans la littérature, elles visent à éviter la phase de clustering pour l'estimation des états [PDM13].

4.4.2.5 Évolution du filtre PHD

La récursivité développée dans le filtre PHD se base sur une élimination des moments supérieurs à l'ordre 1. L'estimation de la cardinalité peut être mauvaise en raison du caractère supposé Poissonien de la distribution de celle-ci. [EWBS05] montre la défaillance du PHD sur l'estimation du nombre d'objets en cas de nombreuses non-détections, de densité de fausse alarme mal évaluée et/ou d'intensité de clutter élevée.

Afin de palier ce problème, Mahler propose une technique pour réduire la variance sur le nombre d'objets estimé : en plus de propager la fonction intensité comme dans le filtre PHD, l'approche propage également la distribution de probabilité sur le nombre de cibles [Mah04, Mah07] en levant l'hypothèse poissonnienne de la densité de probabilité de la cardinalité. Il s'agit du filtre « Cardinalized PHD » (CPHD). Dans un filtre PHD, l'estimation de la cardinalité est influencée par des mesures aberrantes [GW12]. Des modes mineurs peuvent apparaître dans la fonction PHD en raison du clutter ou d'un SNR faible. Le filtre CPHD est alors une solution qui réduit la variance de l'estimation de la cardinalité. Les cibles proches sont de plus mieux différenciées.

Le formalisme CPHD n'est pas présenté dans ce manuscrit. Un descriptif détaillé pourra être trouvé dans les travaux de Mahler [Mah04, Mah07, MVV11]. De manière analogue au PHD, l'implémentation est possible en utilisant une approche par mélange de gaussiennes dans des cas spécifiques [LCB13], ou alors en utilisant les méthodes de Monte-Carlo séquentielles [VVC07].

Les recherches récentes s'intéressent à la notion de cibles étendues et non résolues. En effet, les filtres PHD et CPHD sont des filtres mono-capteurs et leur généralisation au cas multi-capteurs n'est pas implémentable. En effet, le modèle de mesure multi-cibles se base sur les approximations de cible représentée par un point (chaque objet peut être mathématiquement représenté par un point) et de cibles résolues (pas de mesure générée par plus d'une cible). L'usage de capteurs télémétriques implique un placement dans ce cadre spécifique des cibles étendues. Mahler a récemment introduit une généralisation de ses filtres PHD et CPHD pour appréhender le cas de cibles étendues [Mah09] : « Extended Target Tracking PHD » (ETT-PHD). Divers travaux utilisent ces techniques [GLO11, OLG11, GLO12].

4.5 Conclusion

Ce chapitre a permis de présenter deux problématiques liées au suivi multi-cibles :

- le filtrage mono-cible bayésien avec la description de l'ensemble des méthodes permettant d'estimer l'état de la cible. Les méthodes de suivi multi-cibles sont alors dérivées en considérant une indépendance des objets suivis (MHT et JPDA).

- les méthodes de filtrage multi-cibles bayésien qui considèrent l'ensemble des cibles et sa cardinalité comme variables d'état. Les outils implémentés pour résoudre ce problème sont alors le filtre PHD et ses dérivés.

Il convient alors de définir les besoins spécifiques dans le cadre de nos travaux de thèse :

- les filtres de Kalman permettent une mise en oeuvre simple pour l'estimation des états des cibles. Ceux-ci trouvent par contre vite leurs limites en cas de modèles non linéaires et de bruits non gaussiens. Bien que la gaussienneté des bruits sera souvent assurée, les linéarités qui apparaissent dans le modèle de mesure sont très fortes. Le filtrage particulaire se révèle donc indispensable pour assurer la convergence des filtres. De plus, une comparaison entre les méthodes de suivi avec détection et sans détection sera faite. Ces dernières font apparaître de très fortes non-linéarités de modèles et requièrent donc l'utilisation du filtrage particulaire.
- Nous avons choisi une solution basée sur la méthode JPDA avec l'apport de techniques spécifiques concernant la création et la disparition de pistes qui en est son principal inconvénient. De plus, le coût calculatoire de ces méthodes est plus faible que les méthodes de type MHT.
- Quand le nombre d'objets suivis varie peu d'un instant à l'autre, les performances du PHD et CPHD sont similaires [Woo09]. Dans le cadre de suivi de véhicules sur zone routière avec un capteur télémétrique de période d'acquisition élevée, la variation du nombre de véhicules d'un instant à l'autre n'est pas importante (sauf défaillance). L'utilisation du filtre PHD est donc suffisante dans le cadre de nos travaux. En outre, la nécessité d'assurer une continuité des trajectoires des objets nous amène à développer des outils permettant parfois de ne pas prendre en compte l'information sur la cardinalité. Une estimation plus précise de la cardinalité ne serait donc pas nécessaire puisqu'elle doit être mise en perspective avec la complexité induite par les nouvelles équations de récursion. De plus, le temps de réponse du CPHD est plus lent concernant une variation du nombre de cibles [BA12].

Chapitre 5

Suivi d'objets multiples dans une architecture classique avec le détecteur SIP

5.1 Introduction

Dans ce chapitre, on propose d'intégrer les avantages du détecteur SIP dans un processus global de suivi d'objets. La robustesse des méthodes de suivi multi-objets repose sur les méthodes d'association utilisées (JPDA, PHD). Leur efficacité dépend de plusieurs paramètres, tel que l'incertitude sur les observations, la probabilité de détection et de fausse alarme du détecteur, les méthodes de filtrage utilisées, un choix judicieux des modèles de mouvement et bien sûr la méthode de détection.

Les mesures d'entrée du processus de suivi sont obtenues par une étape de segmentation des données télémétriques à chaque instant. Une phase de modélisation permet d'obtenir les mesures du centre de gravité de chaque objet dans le champ de vision du capteur. Dans le chapitre 3, l'étude du détecteur SIP a permis de diminuer l'imprécision et l'incertitude de l'estimation par rapport aux méthodes de segmentation usuelles. L'étape de modélisation est alors également rendue plus robuste.

Les méthodes de suivi utilisées peuvent alors tirer bénéfice de toutes ces améliorations. Le chapitre est divisé en deux parties détaillant pour chacune les deux approches différentes de suivi d'objets multiples présentées dans le chapitre 4 :

- la première partie présente une méthode d'association de données basée sur le JPDA qui permet d'exploiter les dépendances statistiques entre chaque objet. Des outils complémentaires ont été développés pour la gestion de pistes (création, mort, non détections, fausses alarmes) afin de répondre à certaines spécificités de nos travaux.
- la seconde partie met en œuvre un filtre en transformant implicitement l'étape d'association de données, source potentielle d'erreurs. Des outils spécifiques pour la gestion des pistes seront également proposés.

5.2 Modèles de mouvement

Pour les deux approches, on choisit de modéliser le problème de suivi sous forme d'équations d'état et de le résoudre par utilisation du filtrage particulaire en raison des non-linéarités présentes dans le modèle d'observation. Nous avons utilisé des modèles de mouvement qui sont réalistes et robustes en terme de dynamiques possibles pour notre application transport. La perception des capteurs télémétriques mono-plan induit un modèle planaire de mouvement, pour lequel les objets évoluent selon les équations de la cinématique (position, vitesse et accélération). Ce modèle est réputé suffisamment précis pour décrire l'évolution des véhicules aux vitesses considérées.

5.2.1 Modèle de dynamique

On définit le vecteur d'état du mouvement d'un objet par $X = (x, v^x, \gamma^x, y, v^y, \gamma^y)^T$ avec (x, y) les coordonnées du centre de gravité M de l'objet suivi, (v^x, v^y) les vitesses latérale et longitudinale et (γ^x, γ^y) les accélérations latérale et longitudinale. Chaque coordonnée est exprimée dans le repère capteur $R' = (O', \vec{i}', \vec{j}')$, centré sur le capteur et pour lequel \vec{j}' est colinéaire au vecteur vitesse \vec{V}_{ego} du véhicule porteur (fig. 5.1). La période d'échantillonnage des acquisitions du capteur télémétrique est Δt ($\Delta t = 0.1s$ dans notre étude).




FIGURE 5.1 – Repérage spatial : repère monde $R^W = (O_W, \vec{i}_W, \vec{j}_W)$, repère mobile $R' = (O', \vec{i}', \vec{j}')$ et un objet représenté par son centre de gravité M et son vecteur vitesse \vec{V}_M

Le mouvement relatif de l'objet dans ce repère mobile est décrit par un modèle cinématique d'ordre 3 selon les composantes x et y :

$$X_t = f(X_{t-1}, W_t) = F X_{t-1} + W_t \quad (5.1)$$

avec F la matrice de dynamique :

$$F = \begin{pmatrix} F_x & \mathbb{O}_{3 \times 3} \\ \mathbb{O}_{3 \times 3} & F_y \end{pmatrix}, \text{ avec } F_{x,y} = \begin{pmatrix} 1 & \Delta t & \Delta t^2/2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{pmatrix} \quad (5.2)$$

où $\mathbb{O}_{3 \times 3}$ est la matrice nulle de dimension 3. Le bruit de dynamique W_t tient compte de l'hypothèse d'accélération constante du modèle d'état mais inclut également la possibilité de gérer les changements d'accélération (en termes de saut) et d'améliorer la détection de ruptures. Dans cette thèse,

nous avons ainsi choisi un processus à saut :

$$p(W_t) = (1 - \lambda)\mathcal{N}(0, Q) + \lambda A (2\mathcal{U}(0, 1) - 1) \quad (5.3)$$

où λ est la probabilité de saut et où A est le vecteur contenant l'amplitude maximale des sauts fixée *a priori*. La matrice de covariance Q s'obtient en considérant que l'accélération suit un processus de Wiener à temps discret [BSL93] pour aboutir à :

$$Q = \begin{pmatrix} Q_x \sigma_x^2 & \mathbb{O}_{3 \times 3} \\ \mathbb{O}_{3 \times 3} & Q_y \sigma_y^2 \end{pmatrix}, \text{ avec } Q_x = Q_y = \begin{pmatrix} \Delta t^5/20 & \Delta t^4/8 & \Delta t^3/6 \\ \Delta t^4/8 & \Delta t^3/6 & \Delta t^2/2 \\ \Delta t^3/6 & \Delta t^2/2 & \Delta t \end{pmatrix} \quad (5.4)$$

où σ^2 est le vecteur des variances selon chaque composante du bruit W_t qui est à fixer selon les scénarios étudiés afin de permettre une description réaliste des accélérations latérale et longitudinale d'un véhicule (lignes droites, courbes, virages).

5.2.2 Modèle d'observation

Le système est observé par un capteur télémétrique à balayage qui délivre des informations de position et d'orientation sur les véhicules présents dans la scène. L'équation d'observation, en sortie du détecteur, est :

$$Z_t = h(X_t) + \nu_t = \begin{pmatrix} x_t \\ y_t \\ \psi_t \end{pmatrix} + \nu_t \quad (5.5)$$

où ν_t est un bruit blanc gaussien de moyenne nulle et de matrice de covariance R donnée par :

$$R = \begin{pmatrix} \sigma_x^2 & \sigma_{x,y}^2 & 0 \\ \sigma_{x,y}^2 & \sigma_y^2 & 0 \\ 0 & 0 & \sigma_\psi^2 \end{pmatrix} \quad (5.6)$$

R est calculée en fonction des écarts-types des erreurs de mesures σ_ρ et σ_θ en coordonnées polaires. En notant (ρ_M, θ_M) les coordonnées polaires du centre de gravité de l'objet dans le repère capteur, les termes de R peuvent être approchés par linéarisation (section 2.6) avec :

$$\begin{cases} \sigma_x^2 & = \sigma_\rho^2 \cos^2 \theta_M + \sigma_\theta^2 \rho_M^2 \sin^2 \theta_M \\ \sigma_y^2 & = \sigma_\rho^2 \sin^2 \theta_M + \sigma_\theta^2 \rho_M^2 \cos^2 \theta_M \\ \sigma_{x,y}^2 & = \sigma_{y,x}^2 = \frac{\sin(2\theta_M)(\sigma_\rho^2 - \sigma_\theta^2 \rho_M^2)}{2} \\ \sigma_\psi^2 & = \left(\sum_{s=1}^{nb_seg} \sqrt{\sigma_{\theta_s^d}^2} \right)^2 \text{ avec } nb_seg, \text{ le nombre de segments de l'objet modélisé} \end{cases} \quad (5.7)$$

La nature physique du capteur a permis de considérer σ_ρ constant et $\sigma_\theta \approx 0$.

La non-linéarité de la fonction h provient de la composante orientation ψ_t . Il est nécessaire de passer

par un repère fixe, en l'occurrence le repère monde (fig. 5.1), pour prendre en compte la vitesse du véhicule porteur. En effet, l'orientation de l'objet ψ_t dépend du repère capteur R' et donc des vitesses linéaire et angulaire du véhicule porteur, exprimées dans le repère monde. L'orientation de l'objet ψ_t correspond à l'angle du vecteur vitesse exprimé dans le repère R^W et noté $\vec{V}_M^{R^W}$. Dans un premier temps, la rotation du repère capteur R' d'une acquisition à l'autre sera supposée négligeable, puisque les scénarios envisagés seront des configurations en ligne droite, avec ou sans changement de file, et/ou en virages à grand rayon de courbure. De plus, la mesure de cette vitesse angulaire, nécessitant l'apport de capteurs supplémentaires, n'est pas forcément disponible. $\vec{V}_M^{R^W}$ s'exprime par l'application de la loi simplifiée de composition des vitesses :

$$\vec{V}_M^{R^W} = \vec{V}_M^{R'} + \vec{V}_{O'}^{R^W} \quad (5.8)$$

$\vec{V}_{O'}^{R^W}$ la vitesse linéaire du porteur par rapport au repère monde. On notera $\overline{V}^{eg\delta}$ la vitesse linéaire mesurée du porteur, et $\overline{O'M}^{R'}$ et $\vec{V}_M^{R'}$ les composantes positions et vitesses de l'objet suivi. L'orientation ψ'_t de l'objet est alors approchée, à un instant t , par :

$$\psi'_t = \arctan \left(\frac{v_t^y + \|\overline{V}^{eg\delta}\| + \omega_t x_t}{v_t^x - \omega_t y_t} \right) \quad (5.9)$$

Rappelons que l'orientation fournie par le détecteur tient compte uniquement de la direction et pas du sens du déplacement. L'équation d'observation de la composante orientation, qui apporte la non-linéarité de h , doit donc être modifiée pour finalement obtenir :

$$h: \begin{cases} \mathbb{R}^6 \longrightarrow \mathbb{R}^2 \times [0, \pi[\\ X \longmapsto \begin{cases} (x \ y \ \psi')^T & \text{si } \text{sgn}(\psi') \geq 0 \\ (x \ y \ \psi' + \pi)^T & \text{sinon} \end{cases} \end{cases} \quad (5.10)$$

L'orientation peut finalement être obtenue par :

$$\psi_t = \begin{cases} \arctan \left(\frac{v_t^y + \|\overline{V}^{eg\delta}\|}{v_t^x} \right) & \text{si } \text{sgn} \left(\arctan \left(\frac{v_t^y + \|\overline{V}^{eg\delta}\|}{v_t^x} \right) \right) \geq 0 \\ \arctan \left(\frac{v_t^y + \|\overline{V}^{eg\delta}\|}{v_t^x} \right) + \pi & \text{sinon} \end{cases} \quad (5.11)$$

5.3 Suivi d'objets avec détection : SIP-SMC-JPDA

La première méthode de suivi multi-objets prend en considération toutes les pistes et toutes les observations pour effectuer l'étape association. Elle permet de gérer les incertitudes d'association grâce à des regroupements dans des régions de validité communes. La méthode JPDA, présentée dans la section 4.4.1.3, est maintenant implémentée dans le cadre de cette thèse. Plusieurs spéci-

ficités sont ajoutées afin de permettre un suivi robuste relativement aux mesures fournies par le détecteur SIP. En raison de la non-linéarité de la fonction d'observation, les méthodes de Monte Carlo séquentielles ont été mis en œuvre pour fournir une estimation la plus précise possible des paramètres cinématiques des objets. Le formalisme théorique de l'approche est d'abord explicité avec l'utilisation du filtrage particulaire. La méthode, appelée alors SIP-SMC-JPDA, sera évaluée et comparée à une autre méthode (SM-SMC-JPDA) se différenciant par le détecteur (SM).

5.3.1 Cadre théorique

Dans cette approche, chaque objet est étudié indépendamment des autres. En notant $X_t^j = (x_t^j, v_t^{x,j}, \gamma_t^{x,j}, y_t^j, v_t^{y,j}, \gamma_t^{y,j})^T$ le vecteur d'état qui caractérise l'objet j à l'instant t , une approximation particulaire de cet état est obtenue à chaque instant par :

$$\forall j \in \llbracket 1, J_t \rrbracket, \forall i \in \llbracket 1, N_p \rrbracket X_t^j = \sum_{i=1}^{N_p} \omega_t^{j,(i)} \delta_{X_t^{j,(i)}}(X) \quad (5.12)$$

où $X_t^{j,(i)}$ est le vecteur d'état de la particule (i) de l'objet j et $\omega_t^{j,(i)}$ le poids associée. Les poids associés à la même cible sont normalisés :

$$\forall j \in \llbracket 1, J_t \rrbracket, \sum_{i=1}^{N_p} \omega_t^{j,(i)} = 1 \quad (5.13)$$

L'objectif est d'obtenir à chaque instant les poids et positions de chaque particule pour chaque objet selon l'enchaînement des étapes décrites ci-dessous.

5.3.1.1 Initialisation et prédiction

Un nuage pondéré de particules décrivant le mouvement de l'objet est construit autour de chaque état initial \bar{X}_0^j , tel que :

$$\forall j \in \llbracket 1, J_0 \rrbracket, \forall i \in \llbracket 1, N_p \rrbracket, X_0^{j,(i)} \sim \mathcal{N}(\bar{X}_0^j, Q_0) \quad (5.14)$$

Les poids d'importance sont égaux et fixés à $1/N_p$ et la détermination des paramètres initiaux de l'état \bar{X}_0^j sera décrite en 5.3.2.1. Q_0 , la matrice de covariance de l'état initial, qui permet une diffusion du nuage de particules dans l'espace d'état, est donnée par :

$$Q_0 = \text{diag}(\sigma_{0,x}^2, \sigma_{0,v^x}^2, \sigma_{0,\gamma^x}^2, \sigma_{0,y}^2, \sigma_{0,v^y}^2, \sigma_{0,\gamma^y}^2) \quad (5.15)$$

Pour chaque piste j représentée par son nuage à l'instant $(t-1)$, les particules évoluent indépendamment dans l'espace d'état selon la distribution d'importance $q_t(X_t^j | X_{t-1}^{j,(i)}, Z_t)$. Les poids prédits sont alors donnés par :

$$\forall j \in \llbracket 1, J_{t-1} \rrbracket, \forall i \in \llbracket 1, N_p \rrbracket, \omega_{t|t-1}^{j,(i)} = \frac{p(X_t^j | X_t^{j,(i)})}{q_t(X_t^j | X_{t-1}^{j,(i)}, Z_t)} \omega_{t-1}^{j,(i)} \quad (5.16)$$

Nous avons choisi la loi *a priori* comme densité d'importance. Les particules évoluent dans l'espace d'état selon l'équation de dynamique et les poids d'importance prédits sont les mêmes que ceux de l'instant précédent. Le phénomène de rééchantillonnage fréquent, inhérent à ce choix, doit être atténué par une augmentation du nombre de particules dans chaque nuage. La phase de correction qui suit cette étape de prédiction est le point complexe de l'approche et se décompose en plusieurs étapes successives qui sont décrites par la suite.

5.3.1.2 Construction de la matrice d'association

Pour chaque piste j , un nuage de particules prédites est disponible. On peut alors déterminer les mesures prédites en utilisant le modèle d'observation :

$$\forall j \in \llbracket 1, J_{t-1} \rrbracket, \hat{Z}_t^j = \sum_{i=1}^{N_p} \omega_{t|t-1}^{j,(i)} h(X_{t|t-1}^{j,(i)}) \quad (5.17)$$

La matrice d'association Φ dans le cadre JPDA (éq. 4.34), dont les lignes représentent les pistes et les colonnes les mesures, permet de connaître l'ensemble des mesures qui sont potentiellement à l'origine de la piste j . Φ est construite en utilisant un test statistique basé sur la distance de Mahalanobis d_{jm} entre la piste j et la mesure m :

$$d_{jm}^2 = (Z_t^m - \hat{Z}_t^j) S_{jm}^{-1} (Z_t^m - \hat{Z}_t^j)^T \quad (5.18)$$

La matrice d'innovation S_{jm} de la piste j pour l'observation m , dont le bruit est exprimé par R_t^m (éq. 5.40), est définie par :

$$S_{jm} = \sum_{i=1}^{N_p} \omega_{t|t-1}^{(i)} \left(h(X_{t|t-1}^{j,(i)}) - \hat{Z}_t^j \right) \left(h(X_{t|t-1}^{j,(i)}) - \hat{Z}_t^j \right)^T + R_t^m \quad (5.19)$$

Un seuil de décision γ_0 , qui dépend de la probabilité que m soit une observation issue de la piste j présente dans la région de validité et de la dimension de l'espace d'observation, est introduit. Finalement, les coefficients ϕ_{jm} de Φ sont tels que :

$$\phi_{jm} = \begin{cases} 1 & \text{si } d_{jm}^2 \leq \gamma_0 \\ 0 & \text{sinon} \end{cases} \quad (5.20)$$

D'après [Bla86], le volume V_{jm} de cette région de validité est donné par :

$$V_{jm} = \frac{4\pi}{3} \gamma_0^{N_Z/2} \sqrt{|S_{jm}|} \text{ où } N_Z \text{ est la dimension de l'espace d'observation.} \quad (5.21)$$

5.3.1.3 Calcul des probabilités d'association conjointes

Le calcul des probabilités d'association $\beta^{j,m}$ entre la piste j et la mesure m sont ici explicités dans le cadre spécifique de notre application et des modèles choisis. On rappelle que l'objectif est de déterminer la vraisemblance qui permettra de corriger l'état de la piste j , à savoir :

$$p(Z_t|X_t^j) = \beta^{j,0} + \sum_{m=1}^{M_t} \beta^{j,m} p(Z_t^m|X_t^j) \quad (5.22)$$

Un regroupement des pistes est effectué à partir de la matrice d'association Φ selon la procédure décrite dans le paragraphe 4.4.1.3.2.

Notons J_k et M_k le nombre de pistes et d'observations dans un groupe k issu de ce regroupement. On définit la densité spatiale ζ de ce groupe de pistes par :

$$\zeta = \frac{\sum_{j=1}^{J_k} m_j}{\sum_{j=1}^{J_k} V_j} \quad (5.23)$$

avec

- m_j le nombre d'observations associées à une piste j du groupe
- V_j une approximation du volume des régions de validité de la piste j pour les m_j observations
donné par $V_j = \sum_{m=1}^{m_j} V_{jm}$

La densité de probabilité g_{jm} pour une piste j du groupe et une observation m suit une loi gaussienne :

$$g_{jm} = \frac{e^{-d_{jm}^2/2}}{(2\pi)^{N_Z/2} \sqrt{|S_{jm}|}} \quad (5.24)$$

Notons N_H le nombre d'hypothèses du groupe k . On peut alors calculer la probabilité de chaque hypothèse H_l du groupe par produit des différentes probabilités d'association (paragraphe 4.4.1.3.3) :

$$\begin{cases} p(H_0) = \zeta^{J_k} (1 - P_D)^{J_k} \\ p(H_l) = \zeta^{M_c^l} (1 - P_D)^{M_c^l} \prod_{\substack{j \in \llbracket 1, J_k \rrbracket \\ \Theta_l(j) \neq 0}} P_D g_{j\Theta_l(j)} \end{cases} \quad (5.25)$$

où M_c^l est le nombre de mesures non associées à une piste pour l'hypothèse H_l et Θ_l est un vecteur regroupant les indices d'observations associées à chaque piste (éq. 4.38). Après une normalisation des probabilités des hypothèses de chaque groupe, la dernière étape consiste à calculer la probabilité d'association entre la piste j et l'observation m . Elle est obtenue en sommant les probabilités normalisées pour lesquelles cet événement particulier se réalise effectivement :

$$\begin{cases} \beta^{j,m} = \sum_{\mathcal{H}_l | \Theta_l^{(j)} = m} p(\mathcal{H}_l) \\ \beta^{j,0} = 1 - \sum_{m=1}^{M_k} \beta^{j,m} \end{cases} \quad (5.26)$$

5.3.1.4 Correction de l'état des pistes

À partir de la matrice d'association entre les pistes et les mesures, il est donc possible de calculer la vraisemblance pour corriger l'état de la piste j à partir de l'ensemble des M_t mesures. Elle est donnée pour chaque particule d'une piste j par :

$$\forall i \in \llbracket 1, N_p \rrbracket, p(Z_t | X_t^{j,(i)}) = \beta^{j,0} + \sum_{m=1}^{M_t} \beta^{j,m} p(Z_t^m | X_t^{j,(i)}) \quad (5.27)$$

Le choix du modèle d'observation et les statistiques du bruit de mesure permettent de déterminer la vraisemblance de chaque particule, puisque le bruit d'observation suit une loi normale multidimensionnelle de moyenne nulle et de matrice de covariance R^m .

Dans un souci de stabilité numérique, le passage par la log-vraisemblance est privilégié :

$$\begin{aligned} \forall i \in \llbracket 1, N_p \rrbracket, \forall j \in \llbracket 1, J_t \rrbracket, \forall m \in \llbracket 1, M_t \rrbracket, \\ \log \left(p(Z_t^m | X_t^{j,(i)}) \right) = -\frac{1}{2} \left(Z_t^m - h(X_t^{j,(i)}) \right)^T (R_t^m)^{-1} \left(Z_t^m - h(X_t^{j,(i)}) \right) - \log \left((2\pi)^{N_z/2} \sqrt{|R_t^m|} \right) \end{aligned} \quad (5.28)$$

Les poids des particules sont finalement obtenus en intégrant la vraisemblance selon les équations de correction :

$$\forall j \in \llbracket 1, J_t \rrbracket, \forall i \in \llbracket 1, N_p \rrbracket, \omega_t^{j,(i)} = \frac{p(Z_t | X_t^{j,(i)})}{\sum_{l=1}^{N_p} p(Z_t | X_t^{j,(l)})} \omega_{t|t-1}^{j,(i)} \quad (5.29)$$

5.3.1.5 Estimation et rééchantillonnage

L'estimation de l'état de chaque piste se fait classiquement en utilisant les poids d'importance :

$$\forall j \in \llbracket 1, J_t \rrbracket, \hat{X}_t^j = \sum_{i=1}^{N_p} \omega_t^{j,(i)} X_t^{j,(i)} \quad (5.30)$$

Afin d'éviter la dégénérescence du nuage de particules, une phase de rééchantillonnage basée sur la procédure de redistribution multinomiale est appliquée à chaque nuage de particules dans le cas où le nombre de particules efficaces N_{eff} (éq. 5.31) est inférieur à un seuil fixé.

$$\forall j \in \llbracket 1, J_t \rrbracket, N_{eff}^j = \frac{1}{\sum_{i=1}^{N_p} \left(\omega_t^{j,(i)} \right)^2} \quad (5.31)$$

5.3.2 Gestion de pistes

Le processus que nous avons décrit permet d'estimer l'état d'une piste à l'instant t si celle-ci existe à l'instant $(t-1)$. Cette procédure ne prend pas en compte deux notions de gestion de pistes très importantes que sont la création et l'arrêt de pistes. La méthode JPDA dans sa version originale ne permet pas d'automatiser ces deux tâches. Nous proposons dans cette thèse deux outils qui s'articulent autour de la notion de probabilités de détection et de fausse alarme du détecteur. On peut rappeler qu'une probabilité de détection faible ne permet pas d'optimiser une continuité dans le suivi des pistes tandis qu'une probabilité de fausse alarme élevée implique une augmentation du nombre de pistes créées.

La figure 5.2 résume le cheminement des étapes pour une itération de la méthode de suivi JPDA que nous proposons, intégrant la gestion de pistes décrite par la suite.

5.3.2.1 Initialisation de pistes

L'initialisation de pistes se produit dans le cas où une mesure m n'est associée à aucune piste dans la matrice d'association Φ . Cette mesure est donc potentiellement représentative d'une nouvelle piste. L'approche JPDA ne permet pas d'automatiser cette apparition. La nature de la mesure permet d'initialiser le nuage de particules autour des composantes position (x_t^{mes}, y_t^{mes}) du centre de gravité détecté. Le choix des autres paramètres est crucial puisqu'un état mal initialisé induit un nuage de particules mal localisé pouvant conduire à une divergence du filtre dans les premières itérations. La mesure de l'orientation ne donne, en effet, qu'une information de direction du mouvement des objets. Une détermination précise des composantes initiales de la vitesse et de l'accélération est donc indispensable. Ainsi, une solution basée sur un maillage partiel de l'espace d'état est proposée.

Considérons le sous-espace d'état composé des vitesses et des accélérations. En raison de la taille de celui-ci, il semble difficile de construire une grille sur son intégralité. On délimite alors deux bornes de ce sous-espace notées \tilde{X}_{min} et \tilde{X}_{max} . Les valeurs de ces bornes sont à fixer selon le type d'objets suivis et selon une connaissance *a priori* des bornes des valeurs cinématiques des objets. Lors de l'initialisation de cette procédure, N_0 particules $X_0^{(i)}$ sont placées de manière uniforme sur un maillage construit entre \tilde{X}_{min} et \tilde{X}_{max} avec des poids associés $\omega_0^{(i)} = 1/N_0$. Ces particules évoluent alors de manière déterministe (sans bruit de dynamique) selon le modèle d'état du système :

$$\forall i \in [1, N_0], X_t^{(i)} = f(X_{t-1}^{(i)}) \text{ et } \hat{X}_t = \sum_{i=1}^{N_0} \omega_t^{(i)} X_t^{(i)} \quad (5.32)$$

Les poids des particules sont ensuite mis à jour par l'équation de correction d'un filtre particulaire. La procédure d'association est simplifiée par une approche de type plus proche voisin (NN) pour




FIGURE 5.2 – Représentation schématique d'une itération de l'algorithme JPDA avec une méthode de filtrage particulière pour l'estimation des états

ainsi obtenir une mesure $Z_t^{m_0}$:

$$m_0 = \arg \min_{m \in [1, M_t]} \left\{ \left\| Z_t^m - \begin{pmatrix} \hat{x}_t \\ \hat{y}_t \end{pmatrix} \right\|_2 \right\} \quad (5.33)$$

Ce filtre local est répété pendant un nombre d'échantillons n_0 fixé afin de dégager des poids significatifs. Afin de conserver l'information sur le placement des particules, aucune phase de rééchantillonnage n'est appliquée. À l'issue de ce temps n_0 d'initialisation, la particule au poids le plus fort, d'indice i_{max} , est désignée comme la meilleure particule. Les figures 5.3(a) et (b) montrent le résultat du processus à l'issue de la phase d'initialisation. Cette représentation montre le principe du maillage différent en vitesse et en accélération et une répartition différente des poids qui permet d'isoler facilement la particule au poids le plus élevé (entourée dans les deux représentations). Pour assurer une bonne discrimination des paramètres, le temps d'initialisation n_0 doit être suffisamment

long (entre 10 et 20 itérations).

L'évolution étant déterministe, il est donc aisé de connaître les paramètres initiaux $X_0^{(i_{max})}$ et donc de fixer l'état initial de la nouvelle piste :

$$\bar{X}_0 = (x_t^{mes}, v_0^{x,(i_{max})}, \gamma_0^{x,(i_{max})}, y_t^{mes}, v_0^{y,(i_{max})}, \gamma_0^{y,(i_{max})}) \quad (5.34)$$

Le nuage de particules associé à cette nouvelle cible est placé de manière plus ou moins diffuse (cf. paragraphe 5.3.1.1).




FIGURE 5.3 – Détermination de l'état initial d'une piste par maillage : représentation du poids des particules en fonction des composantes (a) vitesses (b) accélérations. La particule sélectionnée est entourée.

Les erreurs du détecteurs (fausses alarmes, non-détection) peuvent perturber ce processus d'initialisation. En effet, la mesure m , non encore associée, point de départ de la procédure, peut être une fausse alarme et/ou un cas de non-détection (pas de $Z_t^{m_0}$ représentatif de l'objet) peut apparaître. L'approche NN sélectionnera alors une mauvaise mesure $Z_t^{m_0}$. Pour contrer ce phénomène, une zone de sélection, bâtie à chaque itération sur une distance fixe choisie, permet de garantir une association cohérente. Si lors d'une des n_0 étapes de la procédure d'initialisation, aucune mesure n'est dans cette zone, la correction n'est pas effectuée et les poids des particules sont conservés en l'état.

5.3.2.2 Arrêt de pistes

Une piste existante à l'instant $(t - 1)$ peut n'être associée à aucune mesure à l'instant t . C'est le cas si l'objet suivi sort du champ de vision du capteur, mais aussi en cas de défaillance du détecteur (non-détection). Il faut donc imaginer un processus capable d'arrêter la piste pour ne plus qu'elle participe aux futurs processus d'association dans le premier cas, mais pas dans l'autre puisque la

non-détection peut simplement être ponctuelle. Un critère simple peut être construit, à savoir « si la piste n'est pas associée, la piste est arrêtée », n'est donc pas envisageable car en cas de non-détection, la piste sera arrêtée puis réinitialisée (nouvelle procédure d'initialisation). Le filtre aura donc à nouveau besoin d'un temps de convergence et les performances globales seront dégradées.

On introduit donc un paramètre supplémentaire à chaque piste, à savoir un horizon temporel, qui correspond au nombre d'itérations successives maximales où elle peut ne pas être associée. Si à un instant t la piste n'est pas associée, on évalue l'horizon temporel :

- s'il est strictement supérieur à 0, alors on conserve l'ensemble des particules prédites de la piste. L'estimation de l'état de la piste se fait donc par somme pondérée de ces particules. La piste est dite alors en prédiction pure. L'horizon temporel est décrémenté, et la piste concernée est conservée dans le processus global de suivi pour l'estimation à l'instant suivant.
- s'il est nul (*i.e.* la piste n'a pas été associée depuis longtemps) alors on considère que l'objet n'est plus visible (sortie du champ de vision ou occultation totale) et la piste est arrêtée à l'instant $(t - 1)$. Le filtre local est libéré.

Lorsqu'une piste est associée, son horizon temporel est automatiquement remis à la valeur initiale fixée.

5.3.3 Expérimentations

Toutes les méthodes de suivi d'objets développées dans ce manuscrit seront évaluées par un processus d'expérimentation commun, d'abord sur données synthétiques pour lesquelles nous connaissons exactement les états des objets de la scène, puis sur des séquences réelles provenant d'acquisitions réalisées sur un circuit. Dans les deux cas, le protocole expérimental (paramètres typiques des capteurs et des algorithmes) sera précisément décrit dans ce chapitre et référencé pour les autres méthodes, avec éventuellement la description de quelques paramètres spécifiques.

5.3.3.1 Données synthétiques

5.3.3.1.1 Présentation

Différents scénarios ont été simulés pour évaluer les méthodes. Nous avons choisi de présenter les résultats d'un scénario suffisamment long en durée et en nombre d'objets total pour que les statistiques des résultats soient représentatives. Pendant 40 secondes, un véhicule porteur se déplace sur une infrastructure composée de 3 voies à vitesse constante (50km/h) avec changement de file. 3 véhicules évoluent dans le champ de vision du télémètre. Différentes configurations de circulation ont été simulées : changement de file, disparition et apparition d'un véhicule, occultation. Les caractéristiques du télémètre sont les suivantes :

- portée maximale de 100m ;
- résolution angulaire $\alpha = 0.25^\circ$;
- champ de vision tel que $\theta_{min} = 10^\circ$ et $\theta_{max} = 170^\circ$;
- fréquence d'acquisition de 10Hz ;

- précision en distance sur les mesures tel que $\sigma_\rho = 0.03\text{m}$, puis $\sigma_\rho = 0.1\text{m}$

5.3.3.1.2 Critères d'évaluation

La méthode SIP-SMC-JPDA est évaluée et comparée avec la méthode SM-SMC-JPDA, comportant la même structure de suivi mais avec un détecteur SM. Plusieurs critères d'évaluation ont été retenus pour cette étude. Dans un premier temps, les méthodes sont comparées en termes de précision d'estimation et l'écart-type de l'erreur d'estimation est calculé pour l'ensemble des pistes de la séquence. Un appariement entre pistes théoriques et pistes estimées est donc nécessaire. Pour ne pas biaiser les comparaisons, une piste théorique est appariée à une seule piste estimée, la plus proche en position. Cette hypothèse exclut donc des statistiques les fausses alarmes. À chaque instant, l'erreur d'estimation est considérée dans l'unique cas où la piste théorique est estimée par les deux méthodes. De plus, le temps de convergence des méthodes étant variable d'une configuration à l'autre, on fixe une période pendant laquelle l'erreur d'estimation n'est pas calculée. Les erreurs d'estimation ne sont donc calculées qu'en régime nominal des filtres. Les statistiques d'erreur sont finalement données selon les normes d'erreur des vecteurs position, vitesse et accélération

Ce critère d'évaluation ne prend donc pas en compte les pistes additionnelles créées qui peuvent être considérées comme des fausses alarmes. L'erreur pour les objets présents dans la scène et non détectés n'est alors pas quantifiée. Deux autres critères sont alors considérés : l'un compare la cardinalité de l'ensemble des objets estimés à chaque instant et le second consiste à calculer la distance OSPA-T entre les pistes estimées et les vraies pistes, dont le nombre est connu à chaque instant. L'erreur sur la cardinalité est donc représentée graphiquement entre le nombre de vraies pistes et le nombre de pistes estimées mettant aussi en évidence les cas de non-détections et de fausses alarmes. L'une des difficultés réside dans la détermination de la cardinalité théorique. Il faut intégrer une notion de visibilité des objets. Un objet sera visible par le capteur et donc supposé présent dans la scène s'il est représenté par au moins 3 impacts et si la longueur visible d'une de ses faces est d'au moins 0.5m (valeur empirique choisie de l'ordre de 25% de la largeur).

La distance OSPA (Optimal SubPattern Assignment) est un critère d'évaluation des méthodes de suivi multi-cibles développé par [SVV08]. Cette métrique généralise, aux ensembles composés de plusieurs objets, la notion de distance de type RMSE en suivi mono-objet entre une quantité référence et son estimée. Cette distance a été modifiée pour intégrer l'aspect multi-pistes, incluant les fausses alarmes, dans l'évaluation, pour aboutir à la distance OSPA-T [RVCV11]. Elle évalue la différence entre l'ensemble théorique composé des pistes avec leurs états respectifs à chaque instant et l'ensemble des pistes estimées. Notons l'ensemble des pistes à chaque instant $T_t = \{X_t^1, \dots, X_t^{J_t}\}$ et l'ensemble des pistes estimées $\hat{T}_t = \{\hat{X}_t^1, \dots, \hat{X}_t^{J_t}\}$. La distance OSPA-T entre ces deux ensembles à chaque instant est :

$$\begin{cases} d_p^{(c)}(T_t, \hat{T}_t) = \left(\frac{1}{\hat{J}_t} \left(\min_{\pi \in \Pi_{\hat{J}_t}} \sum_{i=1}^{J_t} d^{(c)}(X_t^i, \hat{X}_t^{\pi(i)})^p + c^p(n-m) \right) \right)^{1/p} & \text{si } m \leq n \\ d_p^{(c)}(T_t, \hat{T}_t) = d_p^{(c)}(\hat{T}_t, T_t) & \text{sinon} \end{cases} \quad (5.35)$$

où

$d(\cdot, \cdot)$ est la métrique utilisée sur l'espace d'état (norme L2) ;

$d^{(c)}(X_t^i, \hat{X}_t^j)$ est la distance entre X_t^i et \hat{X}_t^j telle que $d^{(c)}(X_t^i, \hat{X}_t^j) = \min(c, d(X_t^i, \hat{X}_t^j))$;

$\Pi_{\hat{J}_t}$ est l'ensemble des permutations sur $[1, \hat{J}_t]$.

La distance OSPA-T utilise deux paramètres fixés selon l'application :

- l'ordre p de la distance OSPA-T qui fixe le poids donné aux mauvaises estimations. Plus p augmente et plus la distance augmente si l'estimation n'est pas suffisamment proche de la valeur théorique. Il est ainsi possible d'avoir une idée de la précision d'estimation en cas de cardinalité égale entre les deux ensembles.
- le paramètre de coupe c qui est la distance maximale autorisée entre les deux ensembles. Celle-ci est généralement atteinte quand les cardinalités ne sont pas les mêmes. La distance OSPA-T permet donc d'avoir une quantification des fausses alarmes dans le processus de suivi puisque c représente la pénalité donnée aux erreurs de cardinalité.

Les paramètres seront respectivement fixés dans notre application à des valeurs communément utilisées [SVV08, MRD12], à savoir $p = 1$ et $c = 1$.

5.3.3.1.3 Résultats

Les filtres SIP-SMC-JPDA et SM-SMC-JPDA ont les mêmes paramètres d'implémentation :

- nombre de particules par cible : $N_p = 5000$;
- probabilité de détection : $P_D = 0.99$;
- seuil de rééchantillonnage : $N_{eff} = 10\% N_p$
- statistiques du bruit de dynamique sur les accélérations : $\sigma_{\gamma_x}^2 = 0.15\text{m/s}^{-2}$ et $\sigma_{\gamma_y}^2 = 0.15\text{m/s}^{-2}$.
Celles sur les positions et les vitesses sont supposées négligeables (éq. 5.4) ;
- l'horizon temporel pour le maintien des pistes en prédiction pure est fixé à 3 itérations
- pour l'initialisation de chaque nouvelle piste, le maillage est construit avec les bornes suivantes différentes selon (x, y) du repère capteur :

latérale	longitudinale
$v_{min}^x = -0.5\text{m/s}$ et $v_{max}^x = +0.5\text{m/s}$	$v_{min}^y = -1\text{m/s}$ et $v_{max}^y = +2\text{m/s}$
$\gamma_{min}^x = -0.3\text{m/s}$ et $\gamma_{max}^x = +0.3\text{m/s}$	$\gamma_{min}^y = -0.5\text{m/s}$ et $\gamma_{max}^y = +0.5\text{m/s}$

Les bornes sont différentes en x et en y puisque la dynamique du véhicule n'est pas la même latéralement et longitudinalement. On répartit uniformément $N_0 = 30000$ particules sur cette grille. La durée de la phase d'initialisation est $n_0 = 20$ itérations.

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
filtre SIP-SMC-JPDA	0.092	0.104	0.128	0.249	0.041	5
filtre SM-SMC-JPDA	0.278	0.216	0.193	0.507	0.075	17

TABLE 5.1 – Écart-type des erreurs d'estimation pour les approches JPDA, distance OSPA-T moyenne et cardinalité pour un bruit de mesure d'écart-type $\sigma_\rho = 0.03m$

- Une fois l'état initial \bar{X}_0 estimé, le nuage de particules est diffusé autour de celui-ci par $Q_0 = \text{diag}(0.1^2, 0.25^2, 0.25^2, 0.1^2, 0.25^2, 0.25^2)$.

Les figures 5.4 et 5.5 montrent les représentations de la norme des composantes position, vitesse et accélération ainsi que l'orientation de chacun des véhicules suivis. Le filtre SM-SMC-JPDA nécessite plus de temps pour correctement initialiser une piste (*cf.* itérations voisines de $t = 50$ et $t = 120$). Ces zones sont en effet des zones où la probabilité de mauvaise modélisation d'un véhicule est élevée soit en raison d'un taux de visibilité restreint, soit d'un défaut du détecteur SM (multiples segments). Plusieurs pistes sont alors successivement créées et détruites avant qu'une convergence ne s'établisse. Le filtre SIP-SMC-JPDA converge plus rapidement puisque SIP est plus performant dans ces zones. En général, dans les mêmes conditions d'initialisation, la première piste créée lors de l'apparition d'un objet est la bonne.

En fonctionnement nominal, les deux filtres se comportent de manière analogue. La continuité des pistes est garantie par le fait qu'une non-détection peut être gérée grâce à l'horizon temporel. Cet horizon temporel permet également de mieux gérer l'arrêt de la piste (*cf.* itération $t = 370$) pour SIP-SMC-JPDA. Le filtre SM-SMC-JPDA se trouve de nouveau dans une configuration plus perturbée avec la création de deux pistes additionnelles. En raison de l'horizon temporel relativement court, les deux méthodes se comportent alors de la même manière (*cf.* $t = 250$ où l'objet le plus éloigné du capteur est occulté).

Les figures 5.5(b) et (c) mettent en avant les perturbations que subissent les estimées par SM-SMC-JPDA relativement à SIP-SMC-JPDA. Les courbes représentant la vitesse et l'orientation montrent des estimations moins perturbées dans le temps par l'approche SIP-SMC-JPDA. Pour l'objet le plus éloigné du capteur, SM-SMC-JPDA présente en particulier deux cas de fausses alarmes et donc deux créations de pistes supplémentaires (*cf.* $t = 50$ et $t = 380$). La méthode SIP-SMC-JPDA n'est pas perturbée par ces fausses alarmes puisque notre détecteur SIP est plus robuste.

Ce gain sur la précision de l'estimation est confirmé par le tableau 5.1. La précision sur les estimations de la position ((facteur 3), de la vitesse ((facteur 2), de l'accélération (facteur 1.5) et de l'orientation (facteur 2) est améliorée, montrant ainsi l'apport du détecteur SIP dans la méthode de suivi JPDA.

L'information sur la distance OSPA-T confirme cette meilleure précision d'estimation, avec une meilleure distance moyenne (facteur 1.8). La figure 5.6(a) illustre une nouvelle fois l'apport du détecteur SIP. Pour la grande majorité des itérations, la distance OSPA-T pour SIP-SMC-JPDA est inférieure à celle pour SM-SMC-JPDA. Les pics de la distance représentent les cas où le nombre




FIGURE 5.4 – Estimations de la norme des composantes pour le SIP-SMC-JPDA : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)

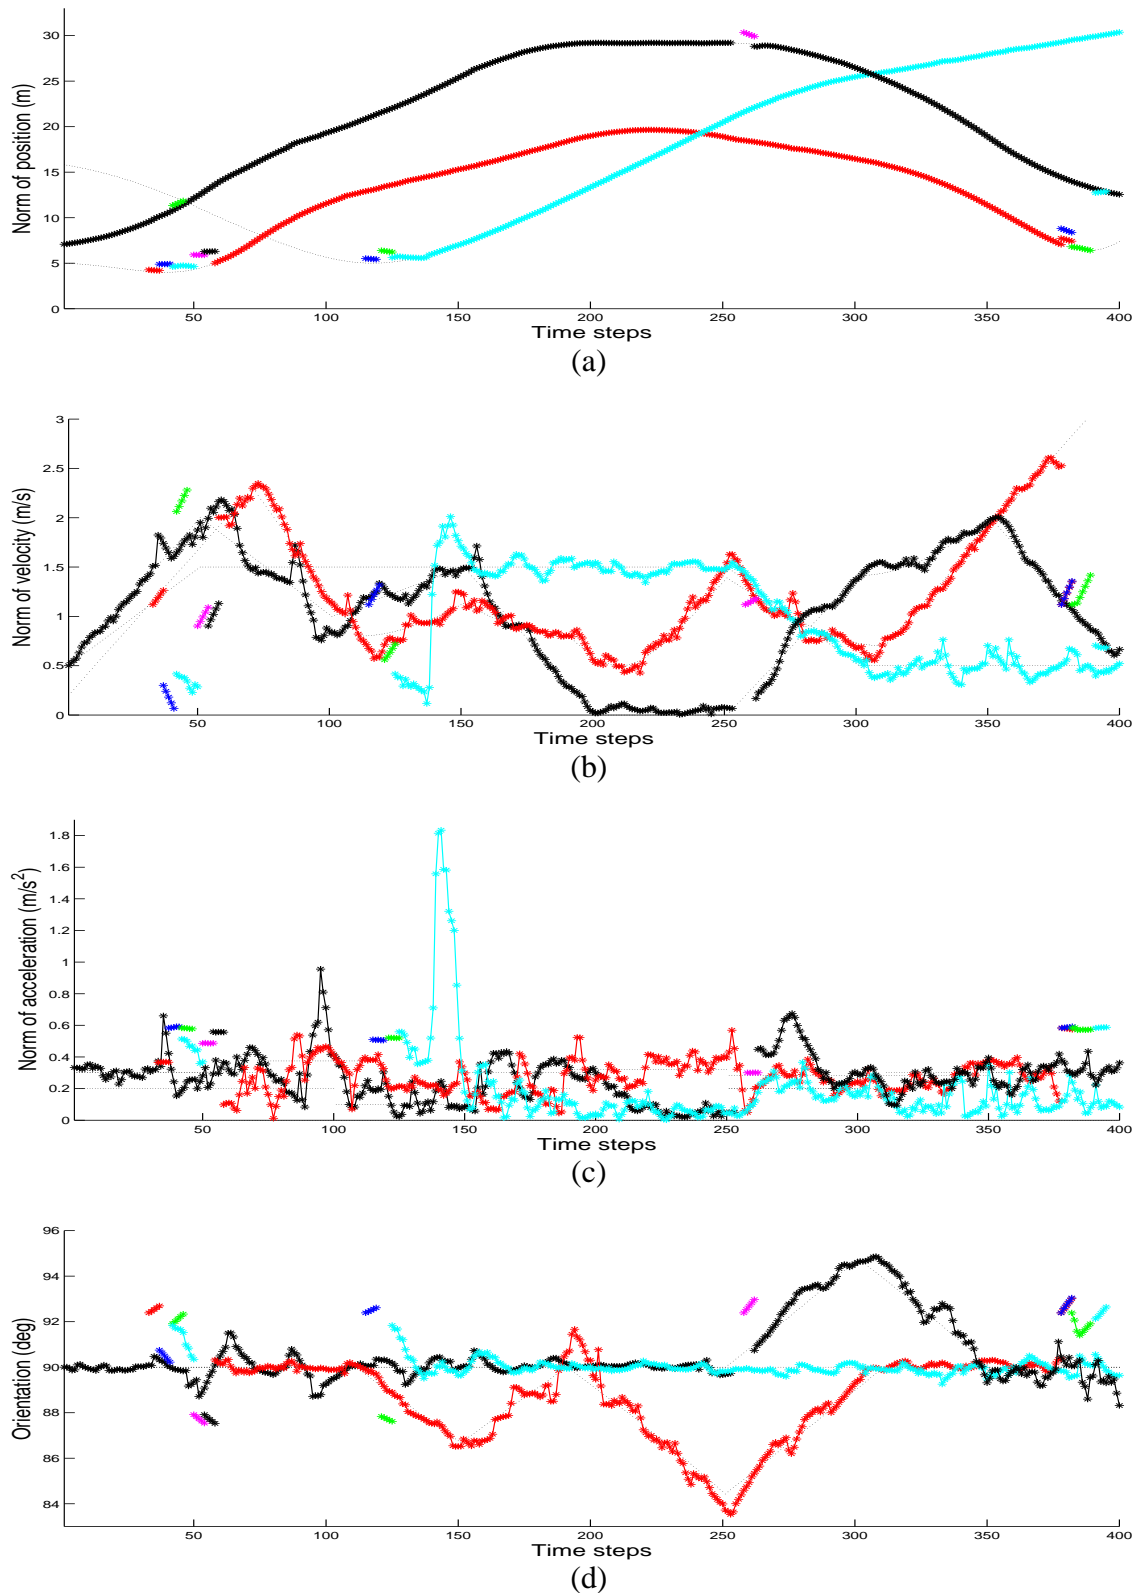


FIGURE 5.5 – Estimations de la norme des composantes pour le SM-SMC-JPDA : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)

de pistes estimées est différent du nombre de pistes théoriques. Ils sont produits soit par des fausses alarmes (plus nombreuses pour le SM-SMC-JPDA), soit par des non-détections. Les figures 5.6(b) et 5.6(c) représentent uniquement les erreurs de cardinalité et la méthode SIP-SMC-JPDA fournit une meilleure estimation de la cardinalité

Pour ce scénario simulé, le nombre de pistes total est parfaitement connu (4 pistes). Si on combine les résultats de la cardinalité et du nombre de pistes créées (table 5.1), la méthode SIP-SMC-JPDA permet de s'approcher du cas idéal avec la création de 5 pistes tandis que SM-SMC-JPDA créé 17 pistes pour le même scénario.




FIGURE 5.6 – (a) Distance OSPA-T à chaque itération pour SIP-SMC-JPDA (noir) et SM-SMC-JPDA (gris) (b) Cardinalité estimée SIP-SMC-JPDA (pointillés) et cardinalité théorique (trait plein) (c) Cardinalité estimée SM-SMC-JPDA (pointillés)

5.3.3.1.4 Robustesse au bruit

Afin de confirmer le gain de performance apporté par le détecteur SIP dans la méthode de suivi, le même scénario a été simulé avec une précision sur les impacts télémétriques plus faible ($\sigma_\rho = 0.1m$). L'ensemble des résultats est résumé dans le tableau 5.2. Même si l'augmentation du bruit de mesure dégrade les résultats des deux méthodes (table 5.1), le filtre SIP-SMC-JPDA conserve son avantage

en termes de précision, et creuse l'écart notamment sur les estimations en position (facteur 3.8) et en orientation (facteur 3). On peut aussi remarquer que la distance OSPA-T est relativement meilleure (facteur 2.6 au lieu d'un facteur 1.8 lorsque $\sigma_\rho = 0.03\text{m}$).

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
filtre SIP-SMC-JPDA	0.172	0.281	0.253	0.497	0.084	7
filtre SM-SMC-JPDA	0.657	0.451	0.240	1.424	0.223	64

TABLE 5.2 – Écart-type des erreurs d'estimation pour les approches JPDA, distance OSPA-T moyenne et cardinalité pour une précision de mesure $\sigma_\rho = 0.1\text{m}$

La figure 5.7(b) illustre la robustesse du filtre SIP-SMC-JPDA face au bruit de mesure du capteur télémétrique en termes de cardinalité puisque la courbe est très proche de la figure 5.6(b). Par contre, pour le filtre SM-SMC-JPDA, les erreurs de cardinalité sont plus nombreuses (fig.5.7(c)). De plus, le suivi est beaucoup moins perturbé en termes de nombre de pistes créées (7 pistes pour SIP-SMC-JPDA contre 64 pistes pour SM-SMC-JPDA). Les avantages du détecteur SIP en termes de segmentation optimale de la scène et de réduction des fausses alarmes est là encore à l'origine de ces derniers résultats.

5.3.3.2 Données réelles

Nous allons définir le protocole utilisé pour l'ensemble des expérimentations en données réelles. Celui-ci sera référencé pour les évaluations de méthodes de suivi, à l'exception de quelques paramètres spécifiques.

Dans le scénario utilisé, le télémètre est installé sur un véhicule porteur se déplaçant en ligne droite avec une vitesse moyenne de l'ordre 60km/h pendant la séquence de 40s. La vitesse instantanée du véhicule porteur est connue à chaque instant d'échantillonnage par un GPS et est intégrée au modèle d'observation. Pendant l'acquisition, deux véhicules évoluent dans la scène. L'un d'eux change de file, masquant ainsi partiellement ou totalement le second. Tenant compte des occultations, des entrées et sorties du champ de vision, 4 pistes effectives sont à suivre durant la séquence.

La difficulté réside dans l'absence de vérité terrain concernant les paramètres cinématiques des objets présents dans le champ du capteur. Les critères d'évaluation retenus sont alors :

- la continuité de la trajectoire des véhicules suivis par représentation de la norme des composantes position, vitesse et accélération ;
- la cardinalité des pistes estimées, que l'on compare à une connaissance supervisée du nombre d'objets présents dans la scène à chaque instant ;
- le nombre de pistes total pendant la séquence.

On rappelle que la précision des mesures est $\sigma_\rho = 0.05\text{m}$.

Les paramètres des filtres sont différents de ceux employés sur les données synthétiques en raison d'une plus forte dynamique des véhicules :

- nombre de particules par cible : $N_p = 10000$;




FIGURE 5.7 – (a) Distance OSPA-T à chaque itération pour SIP-SMC-JPDA (noir) et SM-SMC-JPDA (gris) pour un bruit de mesure d'écart-type $\sigma_\rho = 0.1m$ (b) Cardinalité estimée SIP-SMC-JPDA (trait pointillé) et cardinalité théorique (trait plein) (c) Cardinalité estimée SM-SMC-JPDA (trait pointillé)

- probabilité de détection : $P_D = 0.99$;
- horizon temporel : 3 itérations ;
- statistiques du bruit de dynamique sur les accélérations : $\sigma_{\gamma_x}^2 = 0.5m/s^{-2}$ et $\sigma_{\gamma_y}^2 = 0.8m/s^{-2}$;
- pour l'initialisation des particules, le maillage est construit avec les bornes suivantes différentes selon les composantes longitudinale et latérale :

latérale	longitudinale
$v_{min}^x = -1m/s$ et $v_{max}^x = +1m/s$	$v_{min}^y = -2m/s$ et $v_{max}^y = +2m/s$
$\gamma_{min}^x = -0.5m/s$ et $\gamma_{max}^x = +0.5m/s$	$\gamma_{min}^y = -1m/s$ et $\gamma_{max}^y = +1m/s$

On répartit uniformément $N_0 = 50000$ particules sur cette grille. La durée de la phase d'initialisation est toujours de $n_0 = 20$ itérations.

Les trajectoires des véhicules suivis sont présentées sur les figures 5.9 et 5.10. SIP-SMC-JPDA a créé une piste supplémentaire (cf. $t = 150$) par rapport au nombre optimal de pistes. À cet instant, un véhicule sort du champ de vision du capteur provoquant une mauvaise modélisation de l'objet et

produisant plusieurs fausses alarmes, dont l'une provoque la création d'une piste. La méthode SIP-SMC-JPDA garantit une meilleure continuité de piste, comme le montre le suivi de l'objet le plus proche (cf. $t = 200$ à $t = 300$). Le filtre SM-SMC-JPDA crée alors deux pistes additionnelles alors que SIP-SMC-JPDA maintient la même piste. On peut rappeler que la création de pistes nécessite un processus d'initialisation et un temps de convergence associé qui perturbe le suivi.

Les figures 5.8 montrent la cardinalité obtenue par les deux méthodes. On retrouve bien l'unique piste supplémentaire (cf. $t = 150$) créée par la méthode SIP-SMC-JPDA.




FIGURE 5.8 – (a) Cardinalité estimée SIP-SMC-JPDA (trait pointillé) et cardinalité théorique (trait plein) (b) Cardinalité estimée SM-SMC-JPDA (trait pointillé) (horizon temporel à 3 itérations)

horizon temporel	SIP-SMC-JPDA	SM-SMC-JPDA
0	52	73
1	18	32
2	12	17
3	7	8

TABLE 5.3 – Influence de l'horizon temporel sur le nombre de pistes créées

L'estimation de la cardinalité ne peut pas seulement être représentative de la qualité du détecteur utilisé. En effet, l'horizon temporel introduit permet de palier les défaillances du détecteur et donc de ne pas prendre en compte certaines mesures, les pistes passant alors en prédiction pure. Plus l'horizon temporel est élevé, et moins le filtre sera sensible aux mesures aberrantes fournies par le détecteur. La table 5.3 montre, par le nombre de pistes créées, l'influence de l'horizon temporel sur les filtres. Dans tous les cas, SIP-SMC-JPDA crée moins de pistes que SM-SMC-JPDA diminuant les perturbations de l'étape de suivi d'objets. Les défaillances du détecteur ont une influence inversement proportionnelle à l'horizon temporel. Cependant, le risque de prendre un horizon temporel trop long serait de conserver trop longtemps une piste en prédiction pure, et ainsi de produire une estimation biaisée de l'état de l'objet. L'horizon temporel fixé à 3 itérations est donc un bon compromis.

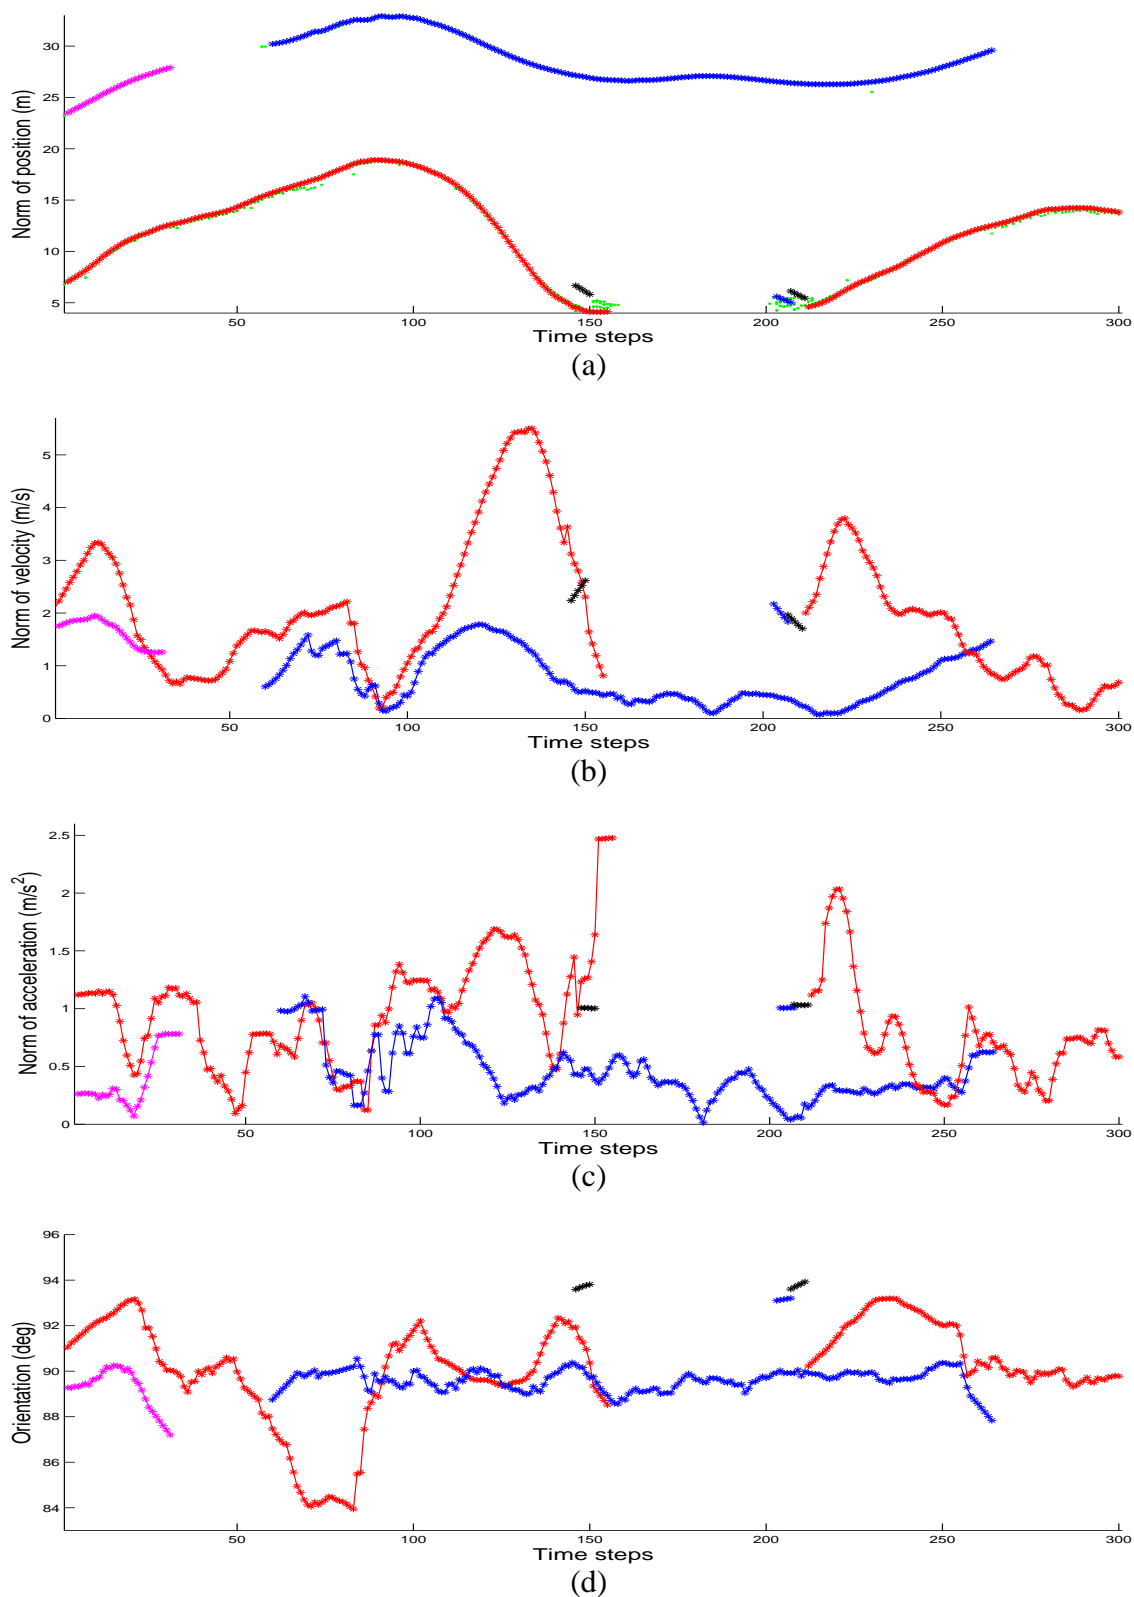


FIGURE 5.9 – Estimations de la norme des composantes pour le SIP-SMC-JPDA : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste est représentée dans une couleur différente. Les détections SIP sont affichées en vert.




FIGURE 5.10 – Estimations de la norme des composantes pour le SM-SMC-JPDA : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste est représentée dans une couleur différente. Les détections SM sont affichées en vert.




FIGURE 5.11 – Trajectoire estimée selon la composante x des véhicules (a) par le filtre SIP-SMC-JPDA (b) par le filtre SM-SMC-JPDA. Les mesures fournies par chaque détecteur sont affichées en vert.




FIGURE 5.12 – Centre de gravité estimé du véhicule suivi (étoile) et centres de gravité détectés (carré) pour le filtre SIP-SMC-JPDA (a) et pour SM-SMC-JPDA (b)

Une contrainte supplémentaire a été introduite dans la création de pistes, à savoir la non création d'une piste dans une zone trop proche d'une piste existante. En effet, il semble trivial que si une mesure non-associée se situe à une distance trop proche d'une piste existante (définie expérimenta-

lement comme une diagonale d'un objet), cette piste est réputée être une même détection de l'objet (phénomène de détections multiples). Dans ce cas, le processus d'initialisation est simplement inhibé pour cette mesure.

Pour terminer la comparaison, nous montrons les effets de cette dernière contrainte (fig. 5.11) par unique représentation de la composante x du vecteur d'état. On observe clairement que le nombre de détections multiples est fréquent pour SM (*cf.* $t = 35$ à $t = 60$ et $t = 260$ à $t = 300$) contrairement à SIP qui est plus robuste. Dans le cas de détections multiples, le filtre SM-SMC-JPDA choisit l'une de ces multiples détections, ce qui explique le nombre de pistes quasi-égal créées, ce qui ne serait certainement pas le cas sans la contrainte de proximité. Par cette contrainte, la cardinalité est certes réduite mais au détriment de l'estimation des paramètres qui est forcément biaisée (fig. 5.12).

5.4 Suivi d'objets avec détection : SIP-SMC-PHD

La seconde méthode proposée de suivi multi-objets utilisant les mesures fournies par le détecteur SIP exploite l'approche PHD (cf. section 4.4.2). Celle-ci présente l'avantage d'éviter les perturbations dans le processus de suivi dues aux erreurs d'association. Le processus d'apparition d'objet est de plus entièrement géré par l'approche PHD en étant directement intégré dans l'étape de pondération. Le modèle d'observation étant similaire à celui utilisé dans la méthode SIP-SMC-JPDA, nous avons choisi les techniques de Monte Carlo séquentielles pour l'implémentation. Cette partie du manuscrit détaille les étapes de la méthode de suivi dénommée SIP-SMC-PHD [FLN13c]. L'idée est d'approximer la fonction intensité (ou fonction PHD) par un ensemble pondéré de particules. Des compléments au filtre PHD de base ont été développés afin de répondre aux besoins spécifiques de notre application en termes de gestion de pistes (création, arrêt et maintien).

5.4.1 Cadre théorique

Dans notre approche de suivi, les états sont regroupés dans un unique ensemble (RFS des états). L'objectif du PHD est d'estimer la cardinalité de ce RFS ainsi que les paramètres de chaque état le composant. Contrairement à la méthode JPDA, l'approximation particulière n'est plus seulement faite sur chaque objet individuellement mais sur l'ensemble des objets de la scène à l'instant courant. La fonction intensité D (éq. 4.60) est approchée par un ensemble de particules de l'espace d'état :

$$D_{t|t}(X) = \sum_{i=1}^{N_t} \omega_t^{(i)} \delta_{X_t^{(i)}}(X) \quad (5.36)$$

où $\omega_t^{(i)}$ représente le poids de la particule i et $X_t^{(i)}$ sa position dans l'espace d'état. N_t désigne le nombre de particules utilisées pour l'approximation particulière. Dans notre cas, celui-ci sera fonction du nombre d'objets détectés par le filtre à chaque instant. Le processus pour l'estimation de ce nombre d'objets et des états de chaque cible est maintenant décrit.

5.4.1.1 Initialisation

Le processus d'initialisation reproduit celui de SIP-SMC-JPDA. Les N_0 particules décrivent cette fois-ci une approximation de la fonction intensité :

$$D_{0|0}(X) = \sum_{i=1}^{N_0} \omega_0^{(i)} \delta_{X_0^{(i)}}(X) \quad (5.37)$$

Bien qu'une initialisation sur tout l'espace d'état soit possible, elle est en pratique très coûteuse d'un point de vue calculatoire. Ainsi, un nuage pondéré de \bar{N} particules décrivant le mouvement de l'objet est construit autour de chacun des J_0 états initiaux \bar{X}_0^j des cibles :

$$\forall j \in \llbracket 1, J_0 \rrbracket, \forall i \in \llbracket 1, \bar{N} \rrbracket, X_0^{j,(i)} \sim \mathcal{N}(\bar{X}_0^j, Q_0) \quad (5.38)$$

où Q_0 est donnée par l'équation 5.15. Les poids d'importance sont fixés à $1/\bar{N}$. Les états initiaux sont partiellement représentés par les mesures de l'instant initial. La détermination des autres paramètres initiaux des états est décrite en 5.3.2.1 et utilise le même processus de maillage que celles des filtres JPDA. Finalement, le nombre total de particules pour l'approximation de la fonction PHD est $N_0 = J_0 \times \bar{N}$ (\bar{N} est le nombre de particules par cible).

5.4.1.2 Prédiction

Les N_{t-1} particules évoluent, selon $q_t(X_t^{(i)}|X_{t-1}^{(i)}, \mathcal{Z}_t)$, dans l'espace d'état. Les poids prédits sont donnés par :

$$\forall i \in \llbracket 1, N_{t-1} \rrbracket, \omega_{t|t-1}^{(i)} = \frac{\varphi(X_t^{(i)}|X_{t-1}^{(i)})}{q_t(X_t^{(i)}|X_{t-1}^{(i)}, \mathcal{Z}_t)} \omega_{t-1}^{(i)} \quad (5.39)$$

Là encore, la loi d'importance q choisie est la loi *a priori*. La loi $\varphi(X_t^{(i)}|X_{t-1}^{(i)})$ utilisée est :

$$\varphi(X_t^{(i)}|X_{t-1}^{(i)}) = p_s(X_t^{(i)})f_{t|t-1}(X_t^{(i)}|X_{t-1}^{(i)}) + \beta_{t|t-1}^s(X_t^{(i)}|X_{t-1}^{(i)}) \quad (5.40)$$

$p_s(\cdot)$ est la probabilité de survie d'une piste de l'instant $t-1$ à l'instant t (supposée fixe) ;

$f_{t|t-1}(\cdot|\cdot)$ est la loi de transition Markovienne mono-cible ;

$\beta_{t|t-1}^s(\cdot|\cdot)$ est la loi des cibles dédoublées.

On considérera que la duplication de véhicules d'un instant à l'autre n'est pas possible, ce qui semble raisonnable pour notre application (si un tel cas était possible, il sera alors géré par les particules exploratrices).

Le filtre PHD permet l'exploration de l'espace d'état par N_t^b particules dont le but est de surveiller l'apparition de nouvelles cibles :

$$\forall i \in \llbracket N_{t-1} + 1, N_{t-1} + N_t^b \rrbracket, X_t^{(i)} \sim p(\cdot|\mathcal{Z}_t) \quad (5.41)$$

Une discussion sur le placement de ces particules exploratrices afin d'optimiser leur répartition dans l'espace d'état aura lieu dans la section 5.4.2.1. Les poids d'importance associés à ces particules exploratrices sont donnés par :

$$\forall i \in \llbracket N_{t-1} + 1, N_{t-1} + N_t^b \rrbracket \omega_{t|t-1}^{(i)} = p(\cdot|\mathcal{Z}_t) \quad (5.42)$$

5.4.1.3 Mise à jour

Pour chacune des $N_t = N_{t-1} + N_t^b$ particules, la mise à jour récursive des poids s'obtient en utilisant les mesures, ainsi que les imprécisions associées, fournies par le détecteur SIP :

$$\forall i \in \llbracket 1, N_{t-1} + N_t^b \rrbracket, \omega_t^{(i)} = \left[1 - p_D(X_t^{(i)}) + \sum_{Z \in \mathcal{Z}_t} \frac{p_D(X_t^{(i)}) L_Z(X_t^{(i)})}{\kappa(Z) + C_t(Z)} \right] \omega_{t|t-1}^{(i)} \quad (5.43)$$

où $C_t(Z)$ est la constante de normalisation :

$$C_t(Z) = \sum_{l=1}^{N_t} p_D(X_t^{(l)}) L_Z(X_t^{(l)}) \omega_{t|t-1}^{(l)} \quad (5.44)$$

$L_Z(\cdot)$ désigne la vraisemblance de chaque particule et s'obtient en utilisant les statistiques de la mesure Z fournies par le détecteur exprimées par la matrice R :

$$L_Z(X_t^{(j)}) = \frac{1}{((2\pi)^{N_z/2} \sqrt{|R|})} \exp \left(-\frac{1}{2} \left(Z - h(X_t^{(j)}) \right)^T R^{-1} \left(Z - h(X_t^{(j)}) \right) \right) \quad (5.45)$$

Contrairement au JPDA, le calcul de cette vraisemblance est réalisée pour le RFS \mathcal{X}_t des états et toutes les mesures du RFS \mathcal{Z}_t .

5.4.1.4 Phase de rééchantillonnage

L'utilisation du filtrage particulière nécessite l'emploi d'une phase de redistribution statistique pour éliminer les particules explorant les zones de l'espace d'état à faible probabilité. Les particules exploratrices dans le filtre PHD requièrent une redistribution à chaque itération. Soit $\left\{ X_t^{(i)}, \omega_t^{(i)} \right\}_{i=1}^{N_t}$ l'ensemble des particules pondérées après les phases de prédiction et de mise à jour. Le nombre estimé de cibles $\hat{N}_{t|t}^T$ s'obtient par une approximation entière (notée round) de la somme des poids :

$$\hat{N}_{t|t}^T = \text{round} \left(\sum_{i=1}^{N_t} \omega_t^{(i)} \right) \quad (5.46)$$

Pour utiliser des méthodes de redistribution, une normalisation des poids par cette valeur est nécessaire. Ainsi, l'ensemble $\left\{ X_t^{(i)}, \omega_t^{(i)} / \hat{N}_{t|t}^T \right\}_{j=1}^{N_t}$ est redistribué en un ensemble $\left\{ \tilde{X}_t^{(j)}, \tilde{\omega}_t^{(j)} / \hat{N}_{t|t}^T \right\}_{i=1}^{\tilde{N}_t}$ selon l'une des méthodes décrites en 4.3.3.2. L'ajout de N_t^b particules exploratrices à chaque itération renforce la nécessité de cette étape de redistribution afin de borner le nombre de particules du processus. Pour cela, le nombre de particules par cible est maintenu autour d'une valeur moyenne \bar{N} , le nombre de particules après rééchantillonnage vaut donc $\tilde{N}_t = \hat{N}_{t|t}^T \times \bar{N}$ qui remplace alors N_t . Les poids $\tilde{\omega}_t$ sont alors remultipliés par $\hat{N}_{t|t}^T$ afin d'obtenir une somme de poids de particules égale à celle avant l'étape de redistribution et le nouveau jeu de particules pondérées $\left\{ \tilde{X}_t^{(s)}, \tilde{\omega}_t^{(s)} \right\}_{s=1}^{N_t}$ est finalement obtenu.

5.4.1.5 Estimation de l'état des cibles

Le filtre PHD fournit une approximation particulière de la fonction intensité à chaque instant. L'estimation de l'état de chaque cible se fait en procédant à une extraction des $\hat{N}_{t|t}^T$ modes estimés de la distribution de probabilité multimodale *a posteriori*. Des algorithmes de clustering sont communément utilisés pour cette opération de séparation des modes (fig. 5.13). Nous avons opté pour l'algorithme des *k-means* qui est communément utilisé dans les approches PHD. Son but est alors de trouver les $\hat{N}_{t|t}^T$ groupes (ou clusters) notés C_k qui minimise, à l'intérieur de chaque groupe, la somme des écarts quadratiques donnée par :

$$\arg \min_{\mathcal{C}} \sum_{k=1}^{\hat{N}_{t|t}^T} \sum_{X_t^{(i)} \in C_k} \left\| X_t^{(i)} - \mu_k \right\|^2 \text{ avec } \mu_k = \frac{1}{\text{card}(C_k)} \sum_{X_t^{(i)} \in C_k} X_t^{(i)} \quad (5.47)$$

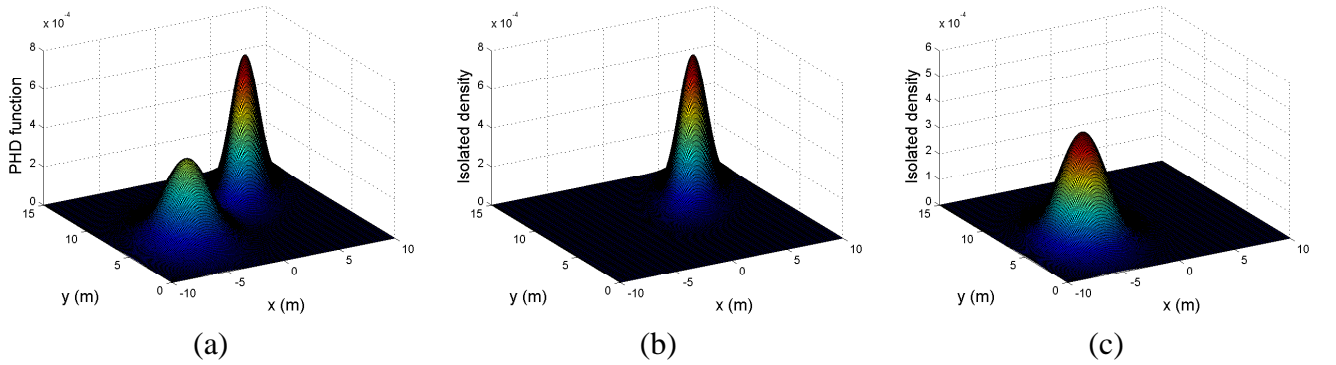


FIGURE 5.13 – Illustration de de l'étape de séparation : (a) densité de probabilité PHD multimodale (représentée dans le sous-espace d'état des composantes positions) (b) et (c) densités de probabilité recherchées après séparation.

La convergence vers des maxima globaux n'est pas assurée et les résultats peuvent dépendre des groupes initiaux fixés. Néanmoins, la rapidité de l'algorithme permet sa répétitivité (avec un nombre maximal d'itérations) dans le cas où des critères de convergence ne seraient pas assurés.

Le centre de chaque groupe représente l'état estimé d'une cible. Pour notre application, une procédure particulière de vérification de séparation des modes a été développée afin de limiter les effets d'un mauvais clustering sur le processus global de suivi. Celle-ci est détaillée dans l'aspect gestion de pistes (section 5.4.2).

5.4.2 Approche orientée piste

5.4.2.1 Placement des particules exploratrices

L'approche PHD permet de surveiller l'espace d'état par la création de N_t^b particules exploratrices parallèlement à la phase de prédiction. La manière la plus triviale de procéder est de placer aléatoirement les particules dans tout l'espace d'état. Néanmoins, la taille de l'espace d'état considéré est très grande en raison de la variabilité des paramètres dynamiques à estimer, impliquant un

nombre exponentiel de particules nécessaires. Dans ce cas, la probabilité qu'une ou plusieurs particules exploratrices soient pondérées avec une mesure représentative d'un nouvel objet sera donc très faible.

La méthode privilégiée est alors de placer ces particules de manière conditionnelle aux observations de l'instant courant $\{Z_t^m\}_{m=1}^{M_t}$. Les N_t^b particules $X_t^{(i)}$ sont uniformément réparties sur l'ensemble des mesures, soit $\lfloor N_t^b/M_t \rfloor$ par mesure avec un poids correspondant $\omega_t^{(i)} = 1/N_t^b$. D'après [RCV10], cette méthode est très efficace en termes de détection d'objets à chaque instant. Elle présente un inconvénient majeur pour les modèles considérés. Si la cible représentée par la mesure produisant le nuage de particules exploratrices existe déjà à l'instant précédent, la dynamique prise par cette cible peut être perturbée puisque le nuage ainsi placé affecte directement l'étape de pondération en position et orientation. Des particules exploratrices mal initialisées selon leurs composantes accélération ne se voient alors pas éliminées par la phase de mise à jour des poids et peuvent ainsi perturber la dynamique antérieurement estimée.

Nous avons donc choisi de modifier cette répartition des particules exploratrices. Pour cela, on analyse simplement la localisation dans le sous-espace des positions de chaque mesure Z_t^m . On construit alors une région autour de chaque mesure prédite $h(X_{t|t-1}^j)$ avec un seuil répondant à la problématique (diagonale d'un véhicule par exemple). Si une observation courante ne tombe dans aucune des régions créées, alors on autorise le placement de particules exploratrices dans le sous-espace d'état correspondant. Afin de trouver les meilleurs paramètres initiaux, une phase d'initialisation basée sur un maillage (*cf.* §5.3.2.1) est là encore mise en œuvre.

5.4.2.2 Trajectographie

Pour notre application, l'inconvénient majeur du filtre PHD est qu'il ne fournit que l'estimation des états des cibles sans notion de piste ou de trajectoire.

Plusieurs techniques ont alors été développées pour construire la trajectoire de chaque cible [PVS05, LBSK06]. Les méthodes proposées dans cette thèse ont été implémentées en utilisant le filtrage particulaire et l'indexation des particules et des clusters [CB05, PBNVC06], lors de l'étape d'estimation, permet alors de donner la notion de pistes au suivi multi-cibles.

L'approximation particulaire de la fonction intensité est donc mise à jour en incluant des index. Ceux-ci sont utilisés pour créer et stocker l'identité de chaque piste. Ils sont propagés avec le jeu associé de particules et rééchantillonnés de la même manière que celles-ci. Considérons un ensemble de $\hat{N}_{t-1|t-1}^T$ pistes existantes $\{\mathcal{T}_{t-1}^k\}_{k=1}^{\hat{N}_{t-1|t-1}^T}$ à l'instant $(t-1)$. À chaque piste est associée un index différent l_{t-1}^k .

Les particules du nuage représentant la dernière estimation $\hat{X}_{t|t}^j$ de la piste sont également indexées avec le même label $l_{t-1}^{(i)} = l_{t-1}^j$. Toutes les particules sont labellisées par :

$$l_t^{(i)} = \begin{cases} l_{t-1}^{(i)} & \text{pour } i = 1, \dots, N_{t-1} \\ 0 & \text{pour } i = N_{t-1} + 1, \dots, N_{t-1} + N_t^b \\ & \text{(particules exploratrices)} \end{cases} \quad (5.48)$$

Après la phase de rééchantillonnage, on dispose donc d'un ensemble de N_t index. Ceux-ci vont permettre de retrouver l'identité de chaque piste, si elle existait à l'itération précédente, mais aussi de créer automatiquement de nouvelles pistes. Notons $\{\mathcal{C}_j\}_{j=1}^{\hat{N}_{t|t}^T}$ le nombre de groupes après la phase d'extraction de modes. Pour associer chaque état estimé (centroïde du groupe) à une piste, on détermine l'index l_t^j le plus représenté dans le groupe (au sens de la pondération) :

$$l_t^j = \arg \max_{l \in \mathcal{L}} \left\{ \sum_{\substack{X_t^{(j)} \in \mathcal{C}_k \\ l_t^{(j)} = l}} \omega_t^{(j)} \right\} \quad \text{où } \mathcal{L} = \left\{ l_t^{(j)} \mid X_t^{(j)} \in \mathcal{C}_k \right\} \quad (5.49)$$

L'association entre la cible j (représenté par son label l_t^j) et la piste \mathcal{T}_{t-1}^k s'effectue alors par simple comparaison des index. Si l'index de la piste à l'instant $(t-1)$ vaut l_{t-1}^j , alors la cible est associée à la trajectoire \mathcal{T}_{t-1}^k augmentée de l'état estimé courant $\hat{X}_{t|t}^j$. Si pour un groupe de particules, le label représentatif est 0, cela signifie que ce sont les particules exploratrices qui se trouvent majoritairement dans ce groupe. Une nouvelle piste est donc créée avec un nouvel index pour les associations futures. Finalement, le processus de trajectographie se résume en :

$$\forall j \in \llbracket 1, \hat{N}_{t|t}^T \rrbracket \begin{cases} \text{si } \exists k \mid \text{index}(\mathcal{T}_{t-1}^k) = l_t^j, \mathcal{T}_t^k = \mathcal{T}_{t-1}^k \cup \{\hat{X}_{t|t}^j\} \\ \text{si } l_t^j = 0, \hat{X}_{t|t}^j \text{ origine d'une nouvelle piste } \mathcal{T}_t^r, r = \max_{i \in \llbracket 1, N_{t-1} + N_t^b \rrbracket} \left\{ l_t^{(i)} \right\} + 1 \end{cases} \quad (5.50)$$

Enfin, les index des particules sont mis à jour en attribuant le label du cluster auxquelles elles appartiennent :

$$\forall i = 1, \dots, N_t, \forall j = 1, \dots, \hat{N}_{t|t}^T, l_t^{(i)} = l_t^j \text{ si } X_t^{(i)} \in \mathcal{C}_j \quad (5.51)$$

Cette méthode de gestion de pistes (maintien et création) est un réel atout puisque, contrairement aux méthodes JPDA, aucune association n'est nécessaire entre les pistes existantes et les mesures de l'instant courant. Pour le processus d'arrêt d'une piste, la phase obligatoire de rééchantillonnage et l'absence d'association nécessite d'adapter la notion d'horizon temporel introduite précédemment (§5.3.2.2). Cet aspect sera développé dans le paragraphe suivant.

5.4.2.3 Arrêt de pistes

La méthode d'indexation des particules permet de construire la trajectoire de chaque cible au cours du temps. Le filtre PHD est cependant très sensible aux imperfections du détecteur. Pour gérer le processus d'arrêt de pistes, nous avons développé une approche utilisant encore une fois la notion

d'horizon temporel, similaire à celle utilisée pour le filtre JPDA (§5.3). Cependant, cette notion doit être adaptée de l'absence d'association.

L'horizon temporel est un indicateur pour chaque piste correspondant au nombre d'itérations maximales durant laquelle une piste n'est pas corrigée. Dans le filtre PHD classique, chaque cible X_{t-1}^j est corrigée, le processus se faisant pour le RFS \mathcal{X}_t complet en utilisant toutes les mesures \mathcal{Z}_t . L'idée est donc d'anticiper les particules qui auront un poids très faible à la sortie de l'étape de pondération et qui ne seront pas conservées à l'issue de l'étape de rééchantillonnage. La cible considérée serait alors non-détectée. Une région, à rayon fixé, dans l'espace des positions est définie autour de chaque piste $h(X_{t-1}^j)$ dans laquelle il existe une forte probabilité qu'une mesure apporte un poids significatif aux particules. Si aucune mesure n'est présente dans cette zone, on conclut que la piste n'est pas représentée et on décrémente son horizon temporel. Deux cas sont possibles :

- l'horizon temporel ne vaut pas encore 0 et il est alors décrémenté. La piste passe alors en prédiction pure. Les particules de son nuage sont exclues du processus de pondération par utilisation de leur index correspondant au label l_t^j de la piste. Ces particules (et leur poids) participent ensuite au processus de rééchantillonnage et à l'estimation des états.
- L'horizon temporel est nul. Aucun traitement particulier n'est alors engagé. Les particules suivent le cheminement normal du filtre PHD. Si leur poids n'est pas significatif, elles seront automatiquement détruites dans la phase de rééchantillonnage. La piste correspondante sera alors arrêtée, puisqu'aucun cluster (à l'issue de l'étape de séparation des modes) n'aura le label l_t^j .

Dans tous les autres cas, l'horizon temporel est remis à sa valeur initiale, indiquant que la cible X_{t-1}^j est effectivement corrigée avec une ou plusieurs mesures significatives.

5.4.3 Vérification de l'étape de séparation des modes (clustering)

L'un des inconvénients du filtre PHD est la dépendance de la qualité de l'estimation à la phase de séparation des modes de la densité multimodale *a posteriori*. L'algorithme des k -means dépend fortement des conditions initiales fixées. L'estimation des états, représentée par les centroïdes des groupes extraits, peut alors être aberrante pour l'application considérée. Plusieurs contraintes à ce clustering ont donc été ajoutées afin de rendre ses résultats les plus exploitables possibles pour le suivi.

Tout d'abord, une contrainte sur la distance entre les cibles est de nouveau utilisée pour répondre à l'hypothèse selon laquelle deux cibles ne peuvent être situées trop proches (seuil d_{thr}) l'une de l'autre. La première vérification du clustering se fait en testant la distance entre les centroïdes de deux clusters \mathcal{C}_1 et \mathcal{C}_2 . Si celle-ci est inférieure à d_{thr} alors on conclut que l'étape de séparation est défailante. Ces clusters sont fusionnés en un unique groupe dont l'index est le plus représenté dans \mathcal{C}_1 et \mathcal{C}_2 (voir 5.4.2.2). On parle alors dans ce cas de fusion de groupes. L'estimation de la nouvelle cible \tilde{X}_t^j se fait alors en déterminant la moyenne pondérée des particules appartenant au groupe fusionné :

$$\tilde{X}_t^j = \sum_{X_t^{(i)} \in \mathcal{C}_1 \cup \mathcal{C}_2} \omega_t^{(i)} X_t^{(i)} \quad (5.52)$$

Le processus est alors répété pour chaque centroïde deux à deux. Finalement, après cette vérification fournissant potentiellement k fusions, le processus de clustering est relancé avec $\hat{N}_{t|t}^T - k$ groupes à trouver dans l'ensemble des particules restantes (les particules des groupes fusionnés sont exclues du nouveau procédé de clustering).

Une autre approche, orientée index, pour la fusion de groupes est également envisageable. Pour chaque cible X_t^j et son index l_t^j respectif, on vérifie si deux groupes ne possèdent pas le même index à l'issue du clustering. Si tel est le cas, ils sont fusionnés en conservant cet index, et on relance le processus de séparation sur les particules qui n'ont pas été fusionnées avec $\hat{N}_{t|t}^T - 1$ modes à extraire.

Pour cette opération de **fusion de groupes**, une deuxième technique utilisant les index des particules est développée. Nous partons cette fois-ci de l'hypothèse que la même cible ne peut être représentée par deux nuages de particules distincts. Ainsi, pour chaque cible X_t^j et son index l_t^j respectif, on vérifie si deux groupes ne possèdent pas le même index à l'issue du clustering. Si tel est le cas, ils sont fusionnés en conservant cet index, et on relance le processus de séparation sur les données qui n'ont pas été fusionnées avec $\hat{N}_{t|t}^T - 1$ modes à scinder.

Ces deux techniques réunies sous une contrainte de **fusion** de clusters permettent de gérer les cas où un groupe unique aurait été scindé en deux groupes distincts.

Un seconde cas de figure est également considérée, *i.e.* un regroupement de particules qui n'appartiennent pas une même cible. Ce phénomène est récurrent dans le cas où les cibles sont proches et il est alors difficile de les séparer. Nous avons donc mis en place une contrainte pour évaluer au sein d'un groupe la dispersion des particules. Les causes de cette dispersion ont deux origines :

- une fusion n'a pas été gérée par la contrainte précédente ;
- le nombre de modes à extraire $\hat{N}_{t|t}^T$ est sous-estimé.

Les centroïdes des groupes, *i.e.* les états estimés, sont alors biaisés par ce mauvais partitionnement. Les particules trop éloignées sont éliminées par le critère :

$$\forall k \in 1, \dots, \hat{N}_{t|t}^T, \forall i | X_t^{(i)} \in \mathcal{C}_k \text{ et } \|X_t^{(i)} - \mu_k\| > d_{max}, \omega_t^{(i)} = 0 \quad (5.53)$$

où d_{max} est un seuil de distance fixe. Afin de conserver la répartition des poids, une étape de normalisation des poids de toutes les particules du cluster est appliquée. Un nouveau rééchantillonnage, sur les particules de ce cluster, est alors nécessaire pour conserver le nombre de particules initial.

Par cette contrainte, une cible ne sera donc pas détectée mais le suivi de l'autre cible sera maintenu. Cependant, des outils additionnels ont été développés pour gérer ces cas de cibles non-détectées (§5.4.2.3).

Finalement, le processus général du filtre PHD est présenté sur la figure 5.14. Le test « groupes cohérents » correspond aux divers tests de contraintes que nous avons introduites dans ces derniers paragraphes.




FIGURE 5.14 – Algorithme général de la méthode PHD proposée

5.4.4 Expérimentations

5.4.4.1 Données synthétiques

La méthode SIP-SMC-PHD a été évaluée et comparée à une méthode de suivi d'objets identique mais qui utilise les mesures fournies par le détecteur SM (filtre SM-SMC-PHD). Le scénario utilisé et le protocole d'évaluation sont les mêmes que ceux présentés pour l'évaluation des filtres JPDA (§5.3.3.1). Des paramètres spécifiques aux algorithmes implémentant des filtres PHD sont adaptés :

- la probabilité de survie d'une piste est fixée à $P_s = 0.95$. En effet, la fréquence d'échantillonnage du télémètre et les scénarios routiers imaginés permettent d'envisager une continuité de la présence des objets dans la scène.
- La densité du clutter suit une loi de Poisson avec une moyenne de 3 impacts par scan.
- Le nombre de particules moyen par cible est fixé à $\bar{N} = 5000$. À chaque itération, $N_t^b = 500$ particules explorent l'espace d'état selon le processus mis en place dans la section 5.4.2.1.

Les trajectoires obtenues sont montrées sur les figures 5.16 et 5.17. Le processus de suivi est nettement plus perturbé avec SM pour les mêmes raisons que celles évoquées dans les expérimentations des filtres JPDA (§5.3.3.1). La continuité des trajectoires est mieux assurée avec SIP-SMC-PHD et montre aussi la robustesse de l'étape d'indexation des particules. La création de pistes supplémentaires, pouvant être induite par des défaillances du détecteur, est ainsi moins fréquente. L'horizon temporel permet de gérer les cas de non-détections et de maintenir la continuité des pistes. On peut cependant remarquer que cet indicateur n'est pas aussi performant lors de l'utilisation du détecteur SM. En effet, dans le cas où un groupe de particules représentatives d'une cible possède un poids plus faible, la conservation de ces poids à l'étape suivante peut amener à l'élimination des particules, en raison de l'approximation entière faite sur le nombre estimé de cibles (*cf.* itération $t = 180$).

L'outil développé pour le placement des particules exploratrices permet de ne pas trop perturber les dynamiques déjà estimées, l'approche orientée piste donnant priorité au maintien. SIP-SMC-PHD permet une initialisation efficace des pistes (*cf.* itérations $t = 120$ et $t = 250$). Avec le détecteur SM, ses défaillances conditionnent directement cette étape d'initialisation puisque des particules sont placées autour des mesures. Le risque de perturbation est donc plus élevé et se traduit par une coupure excessive des pistes et un nombre plus élevé d'initialisations (fig. 5.17).

Pour SIP-SMC-PHD, la variance des estimées est plus faible (table 5.4) et se traduit par une réduction des mouvements parasites, ce qui apparaît sur les courbes 5.17. Le filtre SIP-SMC-PHD améliore la précision d'estimation notamment en position (facteur 2.8), en vitesse (facteur 2.2) et en orientation (facteur 2.4). Le gain est aussi significatif en termes de création de pistes avec 6 pistes (sur 4 théoriques) alors que la méthode SM-SMC-PHD en crée 33.

La table 5.5 montre l'influence de l'horizon temporel sur le nombre de pistes créées. Quel que soit l'horizon temporel choisi, la méthode SIP-SMC-PHD permet toujours de créer moins de pistes.

Si on combine maintenant la cardinalité de l'ensemble estimé à chaque instant et la précision d'estimation, la distance OSPA-T moyenne réduite de moitié pour le SIP-SMC-PHD. La figure 5.15(a) illustre cette meilleure précision. Beaucoup moins de pics sont présents et lorsque les deux

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
filtre SIP-SMC-PHD	0.055	0.079	0.157	0.184	0.037	6
filtre SM-SMC-PHD	0.158	0.174	0.170	0.452	0.082	33


 TABLE 5.4 – Écart-type des erreurs d'estimation, distance OSPA-T moyenne et cardinalité pour les approches PHD pour un bruit de mesure d'écart-type $\sigma_\rho = 0.03m$


FIGURE 5.15 – (a) Distance OSPA-T à chaque itération pour SIP-SMC-PHD (noir) et SM-SMC-PHD (gris) (b) Cardinalité estimée SIP-SMC-PHD (rouge) et cardinalité théorique (noir) (c) Cardinalité estimée SM-SMC-PHD (bleu)

horizon temporel	SIP-SMC-PHD	SM-SMC-PHD
0	30	64
1	15	53
2	13	45
3	6	33

TABLE 5.5 – Influence de l'horizon temporel sur le nombre de pistes créées




FIGURE 5.16 – Estimations de la norme des composantes pour le SIP-SMC-PHD : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)




FIGURE 5.17 – Estimations de la norme des composantes pour le SM-SMC-PHD : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)

méthodes estiment simultanément le même nombre d'objets, SIP-SMC-PHD est plus précis. Ce phénomène est également flagrant sur les figures 5.15(b) et (c) où SM-SMC-PHD donne régulièrement une mauvaise estimation de la cardinalité du RFS des états.

Afin de confirmer le gain de performance apporté par le détecteur SIP dans la méthode de suivi, le même scénario a été simulé avec un bruit de mesure sur les impacts télémétriques plus élevé ($\sigma_\rho = 0.1\text{m}$). La méthode SIP couplée à la méthode de suivi PHD permet de diminuer significativement l'écart-type de l'erreur d'estimation sur la position (facteur 2.2) et sur l'orientation (table 5.6).

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
filtre SIP-SMC-PHD	0.072	0.216	0.294	0.585	0.133	17
filtre SM-SMC-PHD	0.178	0.266	0.275	0.884	0.181	34

TABLE 5.6 – Écart-type des erreurs d'estimation pour les approches PHD, distance OSPA-T moyenne et cardinalité pour un bruit de mesure d'écart-type $\sigma_\rho = 0.1\text{m}$

5.4.4.2 Comparatif des méthodes de suivi JPDA et PHD sur données synthétiques

Nous avons jusqu'à présent comparé des filtres avec les mêmes méthodes de suivi mais des détecteurs différents. Le détecteur SIP amène globalement sur données synthétiques des meilleurs résultats. Il semble intéressant de proposer une comparaison statistique des méthodes de suivi utilisant un détecteur SIP commun. L'évaluation n'est donc plus faite sur la qualité du détecteur, mais sur la méthode de suivi elle-même.

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
filtre SIP-SMC-PHD	0.015	0.086	0.148	0.175	0.052	6
filtre SIP-SMC-JPDA	0.025	0.084	0.135	0.219	0.049	5

TABLE 5.7 – Écart-type des erreurs d'estimation pour les approches SIP-SMC-PHD et SIP-SMC-JPDA, distance OSPA-T moyenne et cardinalité pour une précision $\sigma_\rho = 0.03\text{m}$

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
filtre SIP-SMC-PHD	0.07	0.219	0.285	0.493	0.134	17
filtre SIP-SMC-JPDA	0.086	0.282	0.254	0.613	0.132	7

TABLE 5.8 – Écart-type des erreurs d'estimation pour les approches SIP-SMC-PHD et SIP-SMC-JPDA, distance OSPA-T moyenne et cardinalité pour une précision $\sigma_\rho = 0.1\text{m}$

La table 5.7 résume les résultats pour le scénario avec un bruit de mesure standard ($\sigma_\rho = 0.03\text{m}$). Une légère augmentation de précision est constatée pour le suivi PHD selon les composantes position et orientation et une légère réduction pour les autres composantes. en termes de cardinalité, les deux méthodes se rejoignent avec une distance OSPA-T moyenne quasiment identique. Nous pouvons en

conclure que les deux approches ont des comportements similaires et que les mauvaises détections influent aussi peu sur l'une que sur l'autre.

En augmentant le bruit de mesure (table 5.8), les différences statistiques entre les deux méthodes apparaissent plus significativement. L'approche PHD permet d'améliorer légèrement la précision d'estimation des paramètres cinématiques des objets (sauf en accélération). Par contre, le filtre SIP-SMC-JPDA permet de réduire le nombre de pistes suivies. En effet, pour un bruit de mesure plus élevé, les défaillances du détecteur sont plus nombreuses. Le processus de pondération de l'approche PHD sera donc plus perturbé puisqu'il prend en compte le RFS des mesures à chaque instant, y compris les mesures aberrantes. Une erreur sur l'estimation de la cardinalité du RFS des états entraîne alors un biais dans l'étape de séparation des modes qui peut directement conduire à l'arrêt d'une ou plusieurs pistes. Par contre l'approche JPDA, par son étape d'association, permet de réduire le nombre de mesures avec lesquelles est pondérée chaque piste existante. Il semble donc difficile de classer ces deux méthodes en termes de résultats, chacune d'elle possédant ses avantages et limites.

5.4.4.3 Données réelles

Les méthodes basées sur le PHD sont maintenant testées sur les données réelles identiques à celles utilisées dans la section 5.3.3.2. Tous les paramètres des filtres restent inchangés à l'exception du nombre moyen de particules par cible après rééchantillonnage qu'on fixe à $\bar{N} = 10000$ particules. On rappelle qu'en absence de vérité terrain, les méthodes sont évaluées selon les critères détaillés dans le paragraphe 5.3.3.2.

Les figures 5.18 et 5.19 fournissent les estimations obtenues selon le détecteur utilisé. La méthode SIP-SMC-PHD garantit une meilleure continuité de chaque piste. Les courbes d'estimations sont moins perturbées et présentent moins de saut (fig. 5.9(c)). La robustesse du détecteur SIP permet en effet de réduire les erreurs. C'est notamment le cas lors du passage d'un véhicule dans l'axe du capteur (cf. $t = 30$ à $t = 65$) durant lequel il est uniquement représenté par une face visible. Nous avons montré que le détecteur SIP gère mieux cette configuration que le détecteur SM et donc la qualité du processus de suivi en est améliorée. Ceci conditionne alors directement le nombre de pistes créées et, quel que soit l'horizon temporel, SIP-SMC-PHD crée toujours moins de pistes (table 5.9).

horizon temporel	SIP-SMC-PHD	SM-SMC-PHD
0	30	39
1	15	25
2	13	24
3	12	22

TABLE 5.9 – Influence de l'horizon temporel sur le nombre de pistes créées pour les filtres PHD avec détections

La cardinalité estimée à chaque instant est également comparée à la valeur théorique déterminée de manière supervisée (fig. 5.20). SIP-SMC-PHD permet d'obtenir moins d'erreurs de cardinalité. Le processus de suivi est alors plus robuste et plus stable.

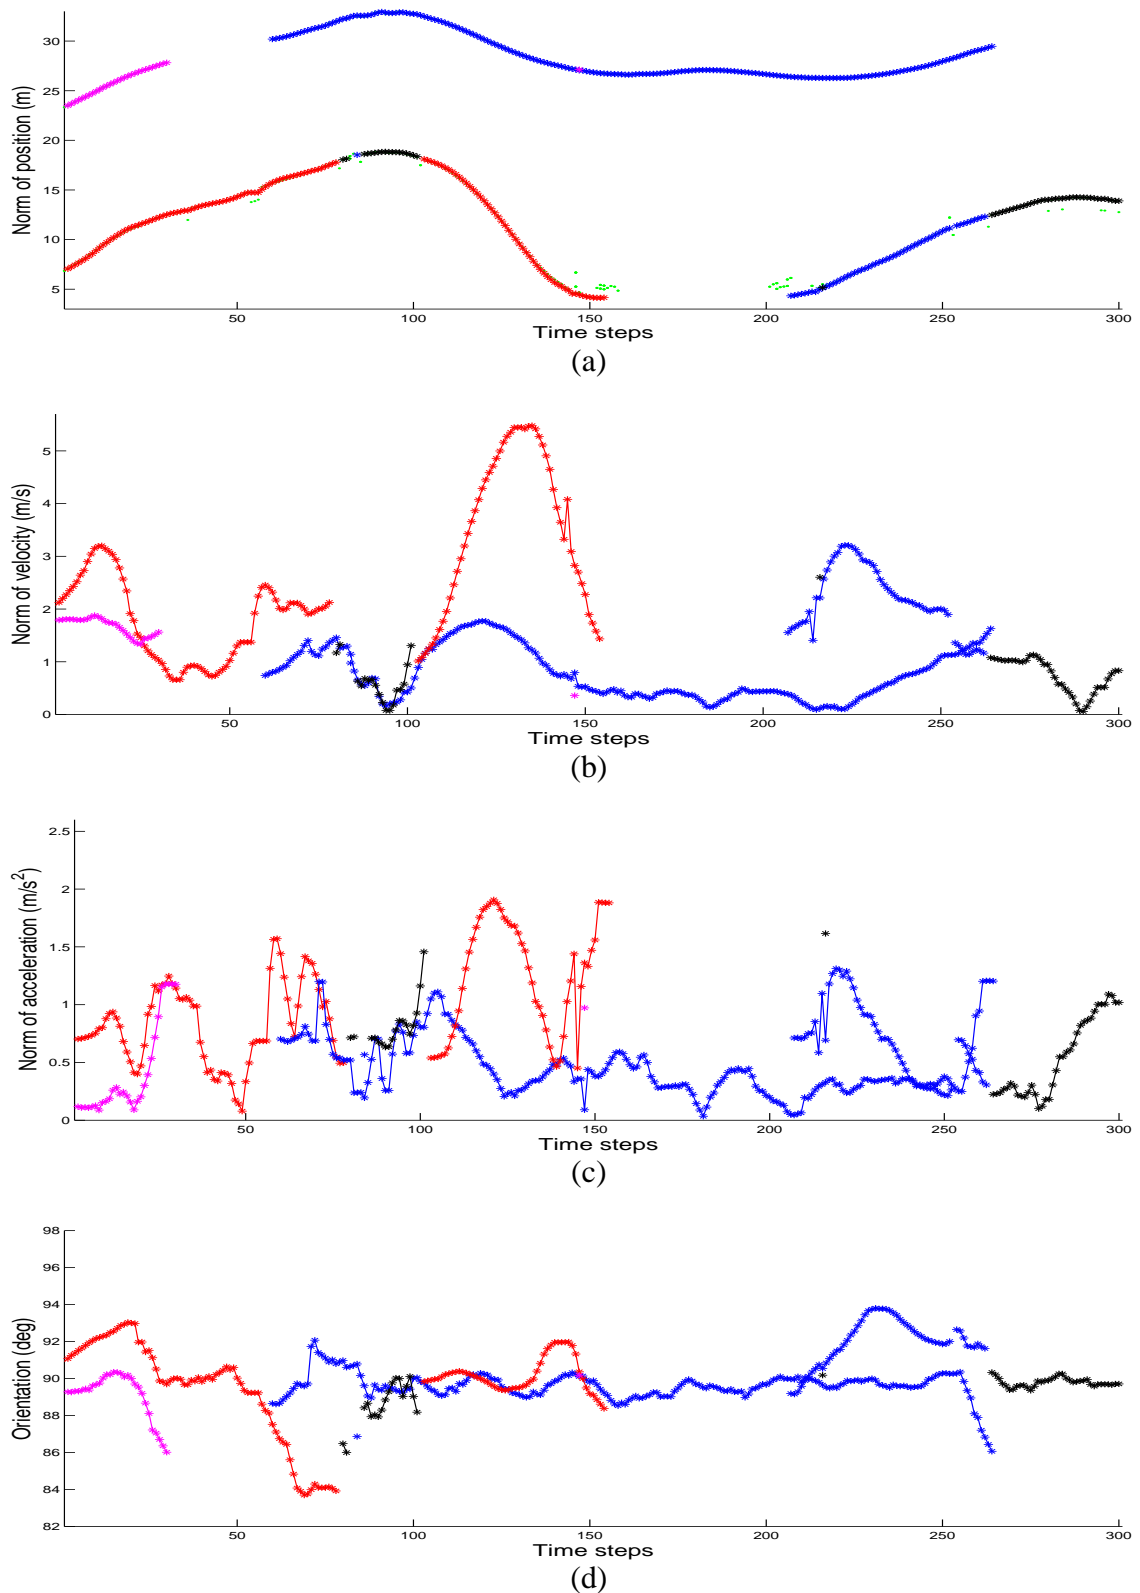


FIGURE 5.18 – Estimations de la norme des composantes pour le SIP-SMC-PHD en ligne droite : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste est représentée dans une couleur différente. Les détections SIP sont affichées en vert.




FIGURE 5.19 – Estimations de la norme des composantes pour le SM-SMC-PHD en ligne droite : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste est représentée dans une couleur différente. Les détections SM sont affichées en vert.




FIGURE 5.20 – (a) Cardinalité estimée SIP-SMC-PHD (rouge) et cardinalité théorique (noir) (b) Cardinalité estimée SM-SMC-PHD (bleu)

5.5 Conclusion

Ce chapitre a permis de proposer deux méthodes de suivi d'objets basées pour l'une sur un filtre JPDA (SMC-JPDA) et pour l'autre sur un filtre PHD (SMC-PHD), mais alimentées par une étape de détection SIP détaillée dans le chapitre 3. On peut donner succinctement les spécificités des deux filtres :

- la méthode JPDA comprend une étape d'association basée sur la notion de région de validité. Cette approche, qui possède un solide cadre de résolution pour estimer l'état de chaque piste en calculant les probabilités d'association, permet de réduire significativement le coût calculatoire. Néanmoins, le nombre de cibles doit être connu à chaque instant cette méthode et ne permet donc pas une initialisation automatique des pistes. De plus, le processus d'association conditionne les performances du filtre. Le gain en coût calculatoire est fortement atténué par des mauvaises associations engendrant des créations excessives de pistes.
- La méthode PHD n'utilise pas explicitement une phase d'association. Le processus de pondération est effectué pour l'ensemble des particules à partir de l'ensemble des mesures de l'espace d'observation. Le formalisme PHD fournit un cadre de résolution efficace pour l'estimation d'un nombre inconnu de cibles à chaque instant. La connaissance du nombre de cibles est simplement déterminée par les poids des particules. Une étape de séparation des modes fournit ensuite l'estimation de chaque piste. L'exploration de l'espace d'état permet en plus de gérer de manière entièrement automatique le processus de création de pistes. Néanmoins, nous avons choisi de conditionner cette étape par les mesures de l'instant courant. Un soin particulier a été apporté au processus de séparation des modes pour contrer les éventuelles défaillances du détecteur.

Pour l'application visée, il est nécessaire d'adapter ces méthodes afin de réduire les effets d'éventuelles défaillances du détecteur. Ces adaptations s'apparentent à des mécanismes de gestion de pistes, à savoir :

- inhiber les effets d'une non-détection sur le processus de suivi. Une piste sera maintenue en

prédiction même si aucune mesure n'entre en compte dans sa pondération. Ce maintien des pistes ne doit pas aboutir à un nombre grandissant d'objets suivis, sans existence réelle. Un horizon temporel permet d'accorder un temps plus ou moins long de maintien en prédiction.

- gérer les apparitions en utilisant un seuillage en distance dans le sous-espace d'état des positions. Dans la méthode JPDA, les mesures non-associées sont classées en deux catégories. La première regroupe les mesures, identifiées comme fausses alarmes, qui répondent au critère de distance entre mesure prédite et observation. Ce cas correspond vraisemblablement à des défaillances du détecteur (mauvaises modélisations) qui n'ont pas de sens physique et aucune piste n'est alors créée. L'autre catégorie de mesure représente potentiellement un nouvel objet. Un processus spécifique de création de pistes permet alors de déterminer les paramètres dynamiques initiaux de ce nouvel objet. Celui-ci utilise un filtre local basé sur un maillage du sous-espace d'état des vitesses et accélérations et une association déterministe des mesures. Après convergence de ce filtre sur quelques itérations, le nuage de particules du nouvel objet est diffusé autour de la meilleure valeur de la grille initiale .

Les deux filtres ont montré de meilleurs résultats lorsqu'ils sont alimentés par le détecteur SIP (vs. SM). Les données synthétiques ont permis de révéler un gain en termes de précision d'estimation des paramètres cinématiques des objets, mais aussi en termes d'estimation de la cardinalité et de continuité des pistes, résultats confirmés sur les données réelles.

Cependant, en utilisant une détection SIP, il paraît difficile de hiérarchiser les deux filtres en termes d'efficacité. Le nombre de pistes suivies est généralement supérieur avec un filtre PHD, mais la précision d'estimation est *a contrario* améliorée. Le filtre PHD permet une gestion automatique de l'initialisation des pistes, tandis que le JPDA nécessite un outil complémentaire à la sortie de l'étape d'association de données. Le JPDA a néanmoins l'avantage de proposer un cadre rigoureux dans le cas où une piste est absente à l'instant courant de l'espace d'observation, tandis que le filtre PHD, par nature, ne permet pas d'identifier cette situation. C'est pour cette raison que nous avons écarté de notre étude le filtre CPHD qui permet théoriquement d'obtenir une meilleure estimation du nombre d'objets. En effet, puisque l'information sur la cardinalité n'est parfois pas prise en compte pour permettre le passage en prédiction d'une piste, il n'est pas nécessaire de développer des méthodes qui estimeraient légèrement mieux celle-ci. De plus, l'intérêt du filtre CPHD est réel dans le cas d'un nombre élevé de cibles à suivre ce qui n'est pas le cas dans notre contexte applicatif.

Quelle que soit la méthode de suivi choisie et les outils complémentaires développés, celle-ci est de toute façon conditionnée par la qualité du détecteur. Les erreurs de segmentation des données télémétriques influencent directement l'étape de modélisation et donc les observations injectées dans le processus de suivi. Dans la suite du manuscrit, des approches de suivi sans détecteur vont être développées et seront comparées à la méthode SIP-SMC-PHD en gardant néanmoins une comparaison avec la méthode de référence SM-SMC-JPDA.

Troisième partie

Suivi basé-modèle par filtrage non linéaire de cibles distribuées

Chapitre 6

Suivi de cibles multiples distribuées basé sur des propriétés d'invariance géométrique

6.1 Introduction

Les méthodes de suivi multi-objets avec pré-traitement des données télémétriques par des étapes de détection et de modélisation (chapitre 5) fournissent un cadre rigoureux de travail. Elles permettent notamment une réduction des données issues du capteur télémétrique en observations représentant par exemple les centres de gravité des objets (cibles ponctuelles). Les processus de gestion de pistes élaborés via une étape d'association de données permettent d'assurer une continuité dans le suivi des objets, nécessaire pour garantir le bon fonctionnement de systèmes d'assistance utilisant ces résultats. Les méthodes d'association et de suivi sont néanmoins conditionnées par la qualité du détecteur utilisé. Si l'étape d'association n'est pas explicitement mise en œuvre dans la section 5.4, le processus de suivi reste lié à la qualité du détecteur. Un point aberrant peut par exemple amener à une segmentation incohérente des données en référence au modèle d'objet suivi *a priori*.

La méthode de suivi développée dans ce chapitre, appelée IP-SMC (« Invariant Parameters tracking with Sequential Monte Carlo methods ») [FLN12b], relève d'une philosophie différente : au lieu de modéliser l'objet à la suite de la phase de segmentation, le modèle est directement intégré dans le filtre. Dans une phase de modélisation classique, l'estimation du centre de gravité est réalisée à partir d'une détection des segments indépendamment du modèle d'objet suivi, avec le risque d'une estimation biaisée. La méthode proposée consiste ici en une approche conjointe de détection et de suivi puisque les données télémétriques en coordonnées polaires sont directement utilisées dans la phase de pondération du filtre. Ce type d'approche requiert cependant une représentation des données compatible avec la phase de suivi. Le développement d'une nouvelle méthode de détection dans les données télémétriques a permis de mettre en évidence le détecteur SIP (chapitre 3) qui utilise les paramètres invariants d'une forme (le segment). L'idée est alors de considérer l'accumulateur construit à partir de la scène télémétrique comme la mise en forme des données précédemment citée et de l'intégrer directement dans le processus d'estimation.

La difficulté d'une telle approche réside dans les fortes non-linéarités de modèle induites par

l'utilisation de la fonction cumulative construite à partir du vecteur d'état. Pour garantir l'optimalité de la solution, les méthodes de Monte Carlo séquentielles sont donc utilisées. De plus, de nouveaux outils doivent être développés pour définir la vraisemblance. Il faut en effet pouvoir, à partir des données télémétriques brutes et leur représentation sous la forme d'un accumulateur, être capable d'amener une discrimination entre des particules représentant effectivement l'objet suivi de celles situées dans un sous-espace d'état à faible probabilité.

Dans la première partie du chapitre, les bases théoriques de la méthode IP-SMC sont explicitées. La méthode de suivi est alors évaluée de manière analogue au chapitre précédent : celle-ci est comparée à trois méthodes de suivi d'objets avec pré-traitement par un détecteur (SIP-SMC-PHD, SM-SMC-PHD et SM-SMC-JPDA) sur des données synthétiques et réelles.

6.2 Modélisation du problème

Contrairement aux différentes méthodes de suivi utilisant une étape de détection conduisant à une estimation des centres de gravité des objets, le modèle d'objet choisi est ici directement intégré dans le filtre. Les deux étapes classiques de prédiction et de pondération sont implémentées. Cette dernière est le point clé de la méthode IP-SMC puisque les impacts télémétriques sont directement considérés. L'accumulateur de la scène est construit et l'objet est directement détecté dans l'accumulateur. La détection et le suivi sont deux phases corrélées, qui ne sont plus perturbées par des étapes de modélisation ou d'association de données.

Le vecteur d'état de l'objet suivi est toujours représenté par $X = (x, v^x, \gamma^x, y, v^y, \gamma^y)^T$. Pour le modèle d'état, on rappelle que le mouvement relatif de l'objet est décrit par un modèle cinématique d'ordre 3 selon les composantes x et y (éqs 5.1 et 5.2).

6.3 Modèle d'observation et vraisemblance associée

6.3.1 Modèle d'observation

Le point clé de la méthode réside dans la phase de mise à jour de la densité de probabilité *a posteriori* : en effet, cette étape est fortement liée à la modélisation de l'équation d'observation, et donc à l'accumulateur. Ainsi, pour chaque objet X_t^j (j est l'indice de l'objet suivi), une mesure Z_t^j doit être déduite. Dans notre approche, la mesure n'est plus représentée par le centre de gravité du véhicule, mais par l'ensemble des impacts télémétriques de la scène correspondante et l'accumulateur associé. Ainsi, en utilisant les caractéristiques du capteur (orientation et résolution angulaire), il est possible de reconstruire l'ensemble des impacts correspondants. À partir de la scène, l'accumulateur CF_t^j de chaque objet est construit et on dispose de deux types de mesures pour la phase de pondération : les données télémétriques et l'accumulateur correspondant.

La reconstruction de la mesure brute est réalisée à partir de l'estimation de la scène, c'est-à-dire en fonction de chaque objet estimé, localisé selon ses composantes positions, et son orientation est

donnée selon la relation utilisée dans le chapitre précédent :

$$\psi_t^j = \arctan \left(\frac{v_t^{y,j} + \|\overrightarrow{V_t^{eg\delta}}\|}{v_t^{x,j}} \right) \quad (6.1)$$

$\overrightarrow{V_t^{eg\delta}}$ est la vitesse du véhicule porteur dans un repère fixe. Celle-ci est estimée en utilisant un capteur GPS par exemple.

À partir de cette scène reconstituée pour une ouverture angulaire $[\theta_{min}, \theta_{max}]$ du champ d'observation du capteur, l'accumulateur est construit. Il est composé de n points ($n = (\theta_{max} - \theta_{min})/\alpha + 1$) et représente pour chaque impact le nombre de voisins maximal appartenant à un même segment. L'accumulateur est noté $\{CF_t(k)\}_{k=1,\dots,n}$ (simplifié en CF_t pour ne pas alourdir la notation). L'équation d'observation est donnée par :

$$Z_t = (Z_t(1), \dots, Z_t(n))^T = (CF_t(1), \dots, CF_t(n))^T = CF_t + \nu_t = H(X_t) + \nu_t \quad (6.2)$$

ν_t est un bruit blanc gaussien n -dimensionnel de covariance $R = \sigma_\nu^2 I_n$ (I_n est la matrice identité d'ordre n). La fonction d'observation H est ici fortement non-linéaire. Chaque objet X_t^j est représenté par un ensemble pondéré de particules $\left\{ X_t^{j,(i)}, \omega_t^{j,(i)} \right\}_{i=1,\dots,N_p}$. Dans ce chapitre, la gestion du suivi se fera indépendamment pour chaque objet.

La qualité d'estimation du filtre est directement conditionnée par la phase de pondération et donc par la vraisemblance $p(Z_t^c | X_t^j)$. Z_t^c représente les mesures brutes du lidar (n impacts $\rho_i, i = 1, \dots, n$) dont la répartition spatiale est parfaitement connue selon la résolution angulaire du capteur :

$$Z_t^c = (\rho_t(1), \dots, \rho_t(n))^T + \nu_t^c \quad (6.3)$$

ν_t^c est un bruit blanc gaussien n -dimensionnel de covariance $\sigma_\rho^2 I_n$ (donnée constructeur). Les données télémétriques sont alors utilisées dans la phase de pondération grâce à un processus d'agrégation. Il s'agit donc dans notre cas de construire une pondération basée sur les accumulateurs permettant d'identifier les particules les mieux localisées et d'éliminer celles à faible probabilité. Une solution, basée sur deux distances utilisant l'accumulateur et les impacts de la scène, a ainsi été formalisée pour définir la vraisemblance $p(Z_t^c | X_t^j)$.

6.3.2 L'accumulateur comme indicateur de partitionnement

L'accumulateur permet de donner une indication du nombre maximal de voisins appartenant au même segment pour un point donné. Si on considère la partie de l'accumulateur représentant un objet (un triangle pour une face visible, et deux triangles pour deux faces visibles), une information concernant le nombre d'impacts appartenant à chaque objet est donc connue. L'objectif est d'utiliser dans un premier temps cette information de regroupement des points pour identifier les particules placées dans un sous-espace d'état à forte probabilité.

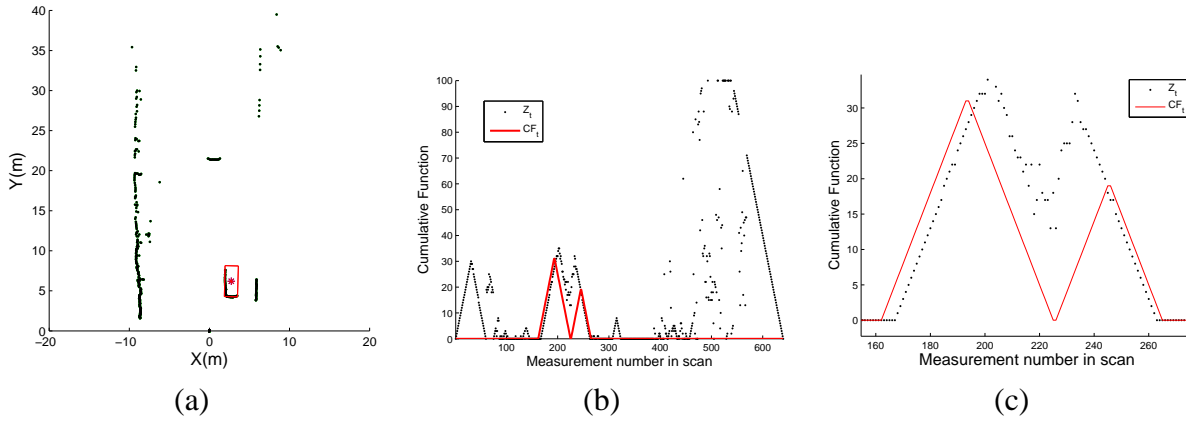


FIGURE 6.1 – (a) scène réelle (scan # 351) en noir et modèle placé dans l'environnement (b) accumulateur de toute la scène (noir) et accumulateur du modèle placé reconstruit à partir des caractéristiques du capteur (rouge) (c) Restriction optimale de l'accumulateur mesuré à l'objet suivi (noir) et accumulateur du modèle (rouge)

Ainsi, une première distance est élaborée : celle-ci doit représenter la similarité qui existe entre deux accumulateurs (l'accumulateur « idéal » de l'objet et l'accumulateur mesuré à chaque instant). La solution triviale est donc de comparer la valeur du voisinage maximal pour chaque impact représentant l'objet. Elle est nécessaire au calcul de la vraisemblance selon l'équation 6.2. Si l'on note Z_t l'accumulateur représentant la mesure, et CF_t^j l'accumulateur théorique construit d'un objet, la distance notée D_{CF}^j est donnée par :

$$D_{CF}^j = \sum_{k=1}^n (Z_t(k) - CF_t^j(k))^2 \quad (6.4)$$

L'inconvénient d'un tel raisonnement est la prise en compte, dans l'accumulateur de la mesure, des impacts qui n'appartiennent pas à l'objet suivi. Ceux-ci affectent directement le calcul de la distance, et la pondération qui en découle. Les figures 6.1 illustrent ce problème : un exemple de scène réelle est montré et l'accumulateur correspondant en noir. Un objet (représenté par une particule) a été placé dans l'environnement, puis son accumulateur « théorique » est construit (tracé en rouge sur la figure 6.1(b) et (c)) après reconstruction de la scène télémétrique. Si l'on calcule la distance selon l'équation 6.4, tous les impacts de l'acquisition (y compris ceux représentant l'environnement extérieur et les autres véhicules) sont pris en compte et rendent alors minime la partie restreinte à l'objet.

Le calcul de la distance doit donc être restreint à une zone spécifique qui caractérise uniquement l'objet suivi. Cela est rendu possible de deux manières :

- en procédant à une sélection de la zone d'intérêt dans l'accumulateur de la mesure (procédure décrite en 6.4) ;
- en restreignant le calcul de la distance D_{CF}^j aux impacts représentant effectivement l'objet.

On suppose dans un premier temps la procédure de sélection de la zone de l'accumulateur mesuré correspondant à l'objet correctement effectuée (figure 6.1(c)). Pour un objet dont les deux faces sont visibles, le chapitre 3, présentant le détecteur SIP, a permis de montrer un phénomène de recouvre-

ment entre les deux pics de la fonction, dû notamment à la proximité du coin. L'accumulateur du modèle théorique idéal ne présente pas cette irrégularité puisque le modèle choisi est parfaitement polygonal (rectangulaire dans notre cas) et la reconstruction des impacts correspondants se fait sans bruit.

Nous avons choisi de ne prendre en compte que les pentes extérieures de l'accumulateur dans le cas où deux faces de l'objet sont visibles, et donc de ne pas se placer à proximité du coin. En effet, on choisit de décrire sous la forme polygonale les objets suivis, ce qui est moins vérifiée dans les coins des objets (carrosserie, pare-choc). En notant \mathcal{I}_1 et \mathcal{I}_2 ces intervalles d'étude, le calcul de la distance permet d'ajuster au mieux le modèle sur les données télémétriques et se fait finalement par :

$$D_{CF}^j = \sum_{k \in \mathcal{I}_1^j \cup \mathcal{I}_2^j} (Z_t(k) - CF_t^j(k))^2 \quad (6.5)$$

Les intervalles \mathcal{I}_1^j et \mathcal{I}_2^j sont nécessaires pour effectuer ce calcul. Leur détermination ne doit pas passer par une utilisation de l'accumulateur de la mesure. En effet, l'objectif est de travailler directement avec les données brutes du capteur via leur représentation sous la forme de la fonction cumulative. Déterminer les pentes à partir de la mesure équivaut alors à effectuer un pré-traitement qui limite les bénéfices de l'approche conjointe de détection et de suivi. Ainsi, c'est le nuage particulaire qui est utilisé pour déterminer les intervalles d'étude.

Le principe est le suivant : pour chaque particule du nuage de l'objet suivi, l'accumulateur idéal est construit, la position des pics déterminée ainsi que les intervalles d'étude propres à chaque accumulateur. La phase de pondération doit être identique pour chaque particule et être réalisée sur un même intervalle qui est construit comme l'union des intervalles d'étude des particules. Ceci permet en outre de déterminer l'extension spatiale de la reconstruction particulaire pour l'objet suivi.

En notant $M^{1,(i)}$ et $M^{2,(i)}$ les deux indices classés où l'accumulateur de la particule présente un maximum local, alors les intervalles d'étude pour le calcul de la distance $D_{CF}^{(i)}$ des N_p particules sont donnés par :

$$\mathcal{I}_1^j = \bigcup_{i=1}^{N_p} \llbracket M^{1,(i)} - CF^{j,(i)}(M^{1,(i)}), M^{1,(i)} \rrbracket \text{ et } \mathcal{I}_2^j = \bigcup_{i=1}^{N_p} \llbracket M^{2,(i)}, M^{2,(i)} + CF^{j,(i)}(M^{2,(i)}) \rrbracket \quad (6.6)$$

Le processus de détermination des intervalles d'étude est illustré sur la figure 6.2 avec uniquement 2 particules.

Même si les données télémétriques sont bruitées et que l'accumulateur mesuré présente des irrégularités (mises en évidence dans la partie 3.2.3.2), chaque particule subira ainsi les mêmes perturbations, ce qui permet de pondérer efficacement les particules dont l'accumulateur est le plus proche de celui de la mesure (sous l'hypothèse de taille du modèle fixe).

Dans le cas où l'objet ne serait visible que par une seule face, alors l'accumulateur se présente sous la forme d'un seul triangle. Dans ce cas, l'intervalle d'étude est représenté par les indices d'impacts des accumulateurs des particules en lesquels la fonction cumulative est non nulle :




FIGURE 6.2 – Détermination de la plage d'étude pour le calcul de la distance entre les accumulateurs.

$$\mathcal{I}^j = \llbracket \arg \min_{l=1, \dots, N_p} \{ \mathcal{CF}^j \neq 0 \} ; \arg \max_{l=1, \dots, N_p} \{ \mathcal{CF}^j \neq 0 \} \rrbracket \text{ où } \mathcal{CF}^j(k) = \sum_{i=1}^{N_p} \mathcal{CF}^{j,(i)}(k) \quad (6.7)$$

Cela revient alors à essayer de mettre en correspondance un seul segment théorique avec les données télémétriques mesurées.

6.3.3 La position du pic central comme information de distance capteur-objet

L'accumulateur, tel que nous l'avons défini et étudié dans la section 3, donne uniquement une information de « clustering ». En effet, en raison de la résolution angulaire du capteur, deux objets localisés à proximité peuvent avoir le même accumulateur (figure 6.3). Ceci s'explique simplement par le fait que des objets localisés différemment peuvent avoir le même nombre d'impacts appartenant aux surfaces visibles, et que ces impacts ont la même répartition spatiale (indices d'impacts de début et de fin d'accumulateur égaux). Ainsi, la pondération construite en utilisant uniquement la distance $D_{CF}^{(i)}$ entre l'accumulateur des particules et l'accumulateur mesuré de la scène amènera à une équipondération des particules, ce qui aboutira à une mauvaise estimation du vecteur d'état.

Afin de fournir un suivi robuste de la forme, la phase de pondération est alors augmentée avec une mesure de distance. Celle-ci est prise en compte en considérant la distance entre le capteur et le point milieu du segment notée D_ρ . Ce point est représenté par un maximum local dans l'accumulateur et il est donc facilement identifiable. Pour un objet dont les deux faces sont théoriquement visibles, on mesure les deux distances entre le capteur et les points milieu afin d'ajuster le modèle de la forme suivie à l'accumulateur mesuré.

Comme pour le calcul de la distance entre les accumulateurs, D_ρ doit être calculée avec la même donnée télémétrique mesurée. Il n'est toujours pas envisageable d'effectuer un prétraitement de l'accumulateur Z_t afin d'obtenir les indices d'impacts correspondant à ces milieux. C'est donc l'état prédit de l'objet par le filtre qui est utilisé : la scène idéale reconstruite avec cet objet est déterminée,




FIGURE 6.3 – Invariance de l'accumulateur autour de la position $(0, 21.5)m$ (zone d'invariance et position de l'objet (carré))

puis l'accumulateur sans bruit est calculé. Celui-ci est noté $\widehat{CF}_{t|t-1}^j$. Comme pour les accumulateurs du nuage particulaire, il est une nouvelle fois possible de trouver exactement les indices des maxima locaux de cet accumulateur, notés u_1^j et u_2^j (si deux faces sont visibles) :

$$\begin{cases} u_1^j = \arg \max_{k=1, \dots, n} \widehat{CF}_{t|t-1}^j \\ u_2^j = \arg \max_{k=1, \dots, n} \left\{ \widehat{CF}_{t|t-1}^j \mid \widehat{CF}_{t|t-1}^j(l) = 0, l \in \llbracket u_1^j - \widehat{CF}_{t|t-1}^j(u_1^j), u_1^j + \widehat{CF}_{t|t-1}^j(u_1^j) \rrbracket \right\} \end{cases} \quad (6.8)$$

Finalement, la distance D_ρ^j entre un objet indicé j et le jeu de données télémétriques est obtenue par :

$$D_\rho^j = \sum_{l \in \{1, 2\}} \left(\rho_t^m(u_l^j) - Z_t^{\rho, j}(u_l^j) \right)^2 \quad (6.9)$$

avec

- ρ_t^m le jeu de coordonnées en distance issue de l'acquisition
- $Z_t^{\rho, j}$ le jeu de coordonnées en distance issue de la reconstruction de la scène
- u_1^j, u_2^j les indices des impacts utilisés pour le calcul de la distance

Si l'objet suivi n'est visible que par une seule face, alors le calcul de la distance D_ρ^j se fait uniquement avec le point milieu du segment visible. Le calcul est illustré sur la figure 6.4 : la distance est bien déterminée dans la direction du tir laser, et donc pour des impacts aux mêmes indices dans la distribution des données télémétriques. Dans tous les calculs effectués, le nombre de faces visibles d'un objet n'est jamais détecté par un traitement quelconque de l'accumulateur mesuré. C'est toujours l'accumulateur reconstruit à partir de l'état prédit de l'objet qui permet de déterminer précisément la position et le nombre de pics pour donner le nombre de faces visibles.




FIGURE 6.4 – Calcul de la distance D_ρ pour le point milieu d'un segment visible : l'impact de la mesure et de la particule (carrés) ont le même indice dans la distribution (modélisé par la ligne du tir laser (pointillés))

6.3.4 Construction de la vraisemblance

Le problème d'invariance des accumulateurs dans un sous-espace d'observation est donc résolu par l'introduction de la distance entre le capteur et l'objet. La phase de pondération peut alors être construite avec les deux distances développées précédemment. Celles-ci permettent de caractériser complètement la position d'un objet dans l'espace d'état. Les mesures des impacts télémétriques permettant de calculer D_ρ sont regroupées sous la notation Z_t^ρ et l'accumulateur mesuré complet de la scène est noté Z_t . L'ensemble des données télémétriques de la scène a été noté Z_t^c . La vraisemblance globale utilisée pour la phase de pondération du filtre est donc le produit des deux vraisemblances basées sur chacune des deux mesures disponibles :

$$p(Z_t^c | X_t^j) = p(Z_t | X_t^j) p(Z_t^\rho | X_t^j) \quad (6.10)$$

Les équations d'observation liées à ces vraisemblances sont :

$$\begin{cases} Z_t &= CF_t + \nu_t \\ Z_t^\rho &= \begin{cases} \begin{pmatrix} \rho_t(u_1) \\ \rho_t(u_2) \end{pmatrix} + \nu_t^\rho & \text{si 2 faces visibles} \\ \rho_t(u_1) + \nu_t^\rho & \text{sinon} \end{cases} \end{cases} \quad (6.11)$$

ν_t est un bruit blanc gaussien n -dimensionnel de moyenne nulle et de covariance $R = \sigma_\nu^2 I_n$ et ν_t^ρ est un bruit blanc gaussien n_s^j -dimensionnel (n_s^j = nombre de faces visibles de l'objet suivi) de moyenne nulle et de covariance $R^\rho = \sigma_\rho^2 I_{n_s^j}$. Un passage par la log-vraisemblance est effectué pour garantir la stabilité numérique :

$$\begin{cases} \log(p(Z_t | X_t^j)) &= -\frac{D_{CF}^j}{2\sigma_\nu^2} - \text{card}(\mathcal{I}_1^j \cup \mathcal{I}_2^j) \log(\sigma_\nu \sqrt{2\pi}) \\ \log(p(Z_t^\rho | X_t^j)) &= -\frac{D_\rho^j}{2\sigma_\rho^2} - n_s^j \log(\sigma_\rho \sqrt{2\pi}) \end{cases} \quad (6.12)$$

$\text{card}(\mathcal{I}_1^j \cup \mathcal{I}_2^j)$ représente le nombre d'impacts qui a été considéré pour le calcul de la distance entre les accumulateurs.

Finalement, la log-vraisemblance pour un objet j est obtenue par l'équation 6.13. Elle est utilisée pour obtenir le poids de chaque particule du nuage approximant l'état de l'objet j .

$$\log(p(Z_t^c | X_t^j)) = \log(p(Z_t | X_t^j)) + \log(p(Z_t^\rho | X_t^j)) \quad (6.13)$$

6.4 Sélection de la zone d'intérêt de l'accumulateur mesuré

La vraisemblance permet de calculer le poids de chaque particule. Elle fait intervenir dans un premier temps le calcul de la distance entre accumulateurs. Il est indispensable que cette distance soit calculée avec la partie de l'accumulateur mesuré qui représente effectivement l'objet suivi. La détermination des intervalles pour limiter le calcul de la distance D_{CF} a permis de trouver des bornes d'indices d'impacts mesurés d'un intervalle que nous notons I_θ^j . Ceci équivaut à des bornes inférieure et supérieure en composante angulaire, que nous notons θ_{min}^j et θ_{max}^j . Avant de procéder au calcul de la distance entre accumulateurs, l'accumulateur de la mesure est simplement modifié (copie en un accumulateur \tilde{Z}_t^j) en mettant à 0 le voisinage maximal des impacts dont la composante angulaire n'est pas comprise entre θ_{min}^j et θ_{max}^j :

$$\forall l \in \llbracket 1, n \rrbracket, \tilde{Z}_t^j(l) = \begin{cases} Z_t(l) & \text{si } l \cdot \alpha \in [\theta_{min}^j, \theta_{max}^j] \\ 0 & \text{sinon} \end{cases} \quad (6.14)$$

Le nuage particulaire de l'objet suivi est utilisé pour déterminer ces paramètres angulaires. Sa propagation plus ou moins diffuse entraîne alors un élargissement de la zone déterminée pour l'utilisation de l'accumulateur \tilde{Z}_t^j dans le calcul de la distance D_{CF} . Si l'on se contente de cette sélection de la zone d'intérêt, la distance D_{CF} ne sera pas uniquement représentative de la similarité entre l'objet suivi et chacune des particules du nuage. Le phénomène d'occultation en est un exemple, puisque les indices d'impacts appartenant aux deux objets sont nécessairement consécutifs. Afin d'éliminer ces composantes de \tilde{Z}_t^j , une sélection des impacts selon leur composante distance a cette fois-ci été imaginée.

Le nuage particulaire est une nouvelle fois utilisé. Il s'agit de profiter des impacts télémétriques des N_p scènes reconstruites de chaque particule. Pour chaque impact dont l'angle est compris entre θ_{min}^j et θ_{max}^j , sa composante distance correspondante à la reconstruction de la scène pour chaque particule est stockée. La détermination des minimum et maximum de cette distance (avec une certaine tolérance si le nuage n'est pas assez diffus) permet de trouver un intervalle $I_\rho^{j,l}$ pour chaque indice l d'impact :

$$\forall l \in I_\theta^j, I_\rho^{j,l} = \left[\min_{1 \leq i \leq N_p} \left\{ Z_t^{\rho,j,(i)}(l) \right\} - \epsilon, \max_{1 \leq i \leq N_p} \left\{ Z_t^{\rho,j,(i)}(l) \right\} + \epsilon \right] \quad (6.15)$$

La comparaison des données télémétriques issues du capteur avec ces valeurs permet alors d'éliminer

les impacts de l'accumulateur non concernés par le suivi de l'objet courant :

$$\forall l \in I_{\theta}^j, \tilde{Z}_t^j(l) = \begin{cases} Z_t(l) & \text{si } \rho_t^m(l) \in I_{\rho}^{j,l} \\ 0 & \text{sinon} \end{cases} \quad (6.16)$$

Finalement, la sélection globale en utilisant ces deux restrictions est schématisée sur la figure 6.5 : la détermination des paramètres angulaires (pour le calcul de la distance D_{CF}) a permis une sélection grossière des données télémétriques qui seront considérées pour la pondération. Cette sélection s'affine ensuite avec le calcul des intervalles I_{ρ}^l (symbolisés par ρ_{min}^l et ρ_{max}^l).




FIGURE 6.5 – Schématisation des opérations de limitation en angle et distance pour la sélection de la zone d'intérêt dans l'accumulateur de la mesure

L'effet successif de ces deux étapes pour la sélection de l'accumulateur mesuré est illustré sur les figures 6.6 où la zone d'intérêt représentant effectivement l'objet suivi apparaît progressivement. L'accumulateur d'une particule d'un nuage approximant un objet a été placé (trait pointillé) afin de montrer la partie de l'accumulateur devant servir à l'étape de pondération.

6.5 Filtre particulaire mis en œuvre

6.5.1 Gestion d'objets multiples

Dans notre approche, chaque objet est suivi indépendamment. Contrairement aux méthodes avec détection, chaque objet dans la scène est représenté de manière unique par une partie de la fonction cumulative. Un suivi indépendant de chaque objet est donc cohérent avec la représentation en accumulateur des impacts télémétriques. Le modèle d'observation étudié, fortement non-linéaire, justifie pleinement l'utilisation des méthodes de Monte-Carlo séquentielles pour la construction de l'étape de filtrage.




FIGURE 6.6 – (a) Accumulateur de la scène acquise par le capteur (noir) et accumulateur d'une particule de l'objet suivi (pointillé) (b) Accumulateur mesuré restreint après la détermination des bornes angulaires (c) Accumulateur final utilisé pour la pondération après l'application du fenêtrage en distance des impacts télémétriques

L'étape de pondération décrite nécessite la connaissance *a priori* du positionnement de chacune des particules afin de déterminer les zones d'intérêt des J_t objets suivis à l'instant t . Tout comme les méthodes de type JPDA, il est donc nécessaire de suivre un nombre d'objets connu à chaque instant. Il est ainsi obligatoire de développer des outils complémentaires visant à automatiser la gestion de pistes pour connaître avant chaque étape de prédiction et pondération des particules le nombre d'objets dans la scène (section 6.6).

6.5.2 Architecture

On rappelle que $X_t^j = (x_t^j, v_t^{x,j}, \gamma_t^{x,j}, y_t^j, v_t^{y,j}, \gamma_t^{y,j})^T$ désigne le vecteur d'état qui caractérise l'objet indicé j à l'instant t . Une approximation particulière de cet état est obtenue à chaque instant en utilisant l'équation 5.12. L'objectif est d'obtenir à chaque instant le poids et la position de chaque particule pour chaque objet selon l'enchaînement des étapes classiques d'un filtre particulaire (section 5.3).

1. Initialisation : un nuage pondéré de particules, et leur poids associé, décrivant le mouvement de l'objet est construit autour de chaque état initial \bar{X}_0^j de la même manière que pour la méthode JPDA (éq. 5.14). La détermination des paramètres initiaux de l'état est une procédure analogue à celle précédemment développée pour les méthodes de suivi avec détecteur et sera décrite dans la section 6.6 pour le cas d'un suivi sans détecteur.

2. Prédiction : pour chaque piste j existante à l'instant $(t-1)$, cette étape est similaire à celle de la méthode JPDA (§5.3.1.1). Les poids prédits sont donnés par l'équation 5.16. L'état prédit de chaque objet est obtenu par la somme pondérée des états prédits des particules :

$$\forall j \in \llbracket 1, J_t \rrbracket, X_{t|t-1}^j = \sum_{i=1}^{N_p} \omega_{t|t-1}^{j,(i)} X_{t|t-1}^{j,(i)} \quad (6.17)$$

Ce sont ces états prédits qui sont utilisés pour trouver les indices d'impacts nécessaire au calcul de la

distance entre le capteur et chaque objet (éq. 6.8) : J_t scènes sont reconstituées en plaçant $X_{t|t-1}^j$ dans l'espace d'observation, et les pics des accumulateurs correspondants permettent de trouver, pour chaque objet, les indices approchant le milieu des faces théoriques visibles. La phase de correction qui suit cette étape est le point complexe de l'approche et se décompose, là encore, en plusieurs étapes successives.

3. Correction :

3.a. Sélection de la zone d'intérêt de l'accumulateur mesuré : la procédure expliquée en 6.4 est appliquée pour chacun des J_t objets. Celle-ci permet une association entre l'objet suivi et sa mesure, représentée par la partie de l'accumulateur correspondant, si celle-ci existe.

3.b. Distance entre accumulateurs : à partir de la restriction de l'accumulateur, les distances entre les accumulateurs particulières $CF_t^{j,(i)}$ et l'accumulateur de la mesure noté \tilde{Z}_t^j sont calculées par :

$$D_{CF}^{j,(i)} = \sum_{k \in \mathcal{I}_1^j \cup \mathcal{I}_2^j} (\tilde{Z}_t^j(k) - CF_t^{j,(i)}(k))^2 \quad (6.18)$$

\mathcal{I}_1^j et \mathcal{I}_2^j sont les intervalles d'indices d'impacts relatifs à chaque objet pour le calcul de la distance D_{CF} .

3.c. Distance capteur-particule : la distance entre le capteur et chacune des particules est calculée (section 6.3.3). La reconstruction de la scène télémétrique avec l'objet prédit $X_{t|t-1}^j$ et de l'accumulateur correspondant $CF_{t|t-1}^j$ permet de connaître les indices d'impacts utilisés pour l'évaluation de la distance entre le capteur et les particules :

$$\begin{cases} u_1^j = \arg \max_{k=1, \dots, n} CF_{t|t-1}^j \\ u_2^j = \arg \max_{k=1, \dots, n} \left\{ CF_{t|t-1}^j \mid CF_{t|t-1}^j(l) = 0, l \in \llbracket u_1^j - CF_{t|t-1}^j(u_1^j), u_1^j + CF_{t|t-1}^j(u_1^j) \rrbracket \right\} \end{cases} \quad (6.19)$$

La distance entre l'objet suivi j et chacune des particules du nuage est obtenue par :

$$D_\rho^{j,(i)} = \sum_{l \in \{1,2\}} \left(\rho_t^m(u_l^j) - Z_t^{\rho,j,(i)}(u_l^j) \right)^2 \quad (6.20)$$

3.d. Mise à jour des poids des particules : il est maintenant possible de procéder à la mise à jour des poids des particules. Notons $L_Z^{j,(i)}$ la log-vraisemblance de chaque particule du nuage d'un objet j . En raison de la grande dimensionnalité de l'équation de mesure, la distance entre les accumulateurs peut être très élevée avec pour conséquence une densité de probabilité *a posteriori* très étroite qui rend alors difficile la discrimination des particules représentatives. Pour éviter une discrimination extrême, ces distances doivent donc être étalées pour finalement obtenir la log-vraisemblance, par exemple avec l'opérateur logarithmique :

$$L_Z^{j,(i)} = -\frac{\log(D_{CF}^{j,(i)})}{2\sigma_\nu^2} - \text{card}(\mathcal{I}_1^j \cup \mathcal{I}_2^j) \log(\sigma_\nu \sqrt{2\pi}) - \frac{D_\rho^{j,(i)}}{2\sigma_\rho^2} - n_s^j \log(\sigma_\rho \sqrt{2\pi}) \quad (6.21)$$

Finalement, dans un souci de discrimination des poids, la mise à jour s'effectue avec au préalable une mise à l'échelle des log-vraisemblances :

$$\forall j \in \llbracket 1, J_t \rrbracket, \forall i \in \llbracket 1, N_p \rrbracket, \omega_t^{j,(i)} = \frac{\exp(\log(\omega_{t|t-1}^{j,(i)}) + L_Z^{j,(i)} - m_s)}{\sum_{l=1}^{N_p} \exp(\log(\omega_{t|t-1}^{j,(i)}) + L_Z^{j,(i)} - m_s)} \quad (6.22)$$

avec $m_s = \min_{i=1, \dots, N_p} \left\{ \log(\omega_{t|t-1}^{j,(i)}) + L_Z^{j,(i)} \right\}$.

L'état estimé de chaque objet est calculé classiquement par :

$$\forall j \in \llbracket 1, J_t \rrbracket, \hat{X}_t^j = \sum_{i=1}^{N_p} \omega_{t|t-1}^{j,(i)} X_{t|t-1}^{j,(i)} \quad (6.23)$$

4. Rééchantillonnage : cette procédure est identique à celle décrite dans la section 5.3.1.5.

6.6 Gestion de pistes

Le processus que nous avons décrit permet d'estimer l'état d'une piste à l'instant t si celle-ci existe à l'instant $(t-1)$. Comme la méthode JPDA, il est nécessaire d'estimer *a priori* le nombre de pistes à suivre. Ainsi, des outils de création et destruction de pistes ont été développés.

6.6.1 Création de pistes

6.6.1.1 Instant initial

Ce processus entre en jeu dans la phase d'initialisation du filtre, mais il peut également être une solution de veille pour gérer l'apparition de nouveaux objets.

Pour l'initialisation des états des particules, le détecteur SIP permet *a priori* d'estimer la position du centre de gravité de chaque objet, issue d'une phase de modélisation par le même modèle que celui considéré dans le filtre (rectangle de taille fixe ici). Pour trouver les autres composantes du vecteur d'état et ainsi initialiser une nouvelle piste, nous avons choisi d'implémenter une solution basée sur un maillage du sous-espace d'état composé des vitesses et accélérations (section 5.3.2.1). Dans le cadre de cette méthode de suivi, le détecteur SIP permet uniquement d'initialiser le nuage de particules dans une zone de l'espace d'état où un nouvel objet est apparu. Le processus d'initialisation reprend le même principe que dans le paragraphe 5.3.2.1 où les mesures issues du détecteur sont ici remplacées par la fonction cumulative. Ce filtre local spécifique à l'initialisation est libéré au

bout d'un temps t_{init} (une seconde par exemple), puis les particules les mieux placées initialement sont repérées grâce à leur poids plus élevé.

6.6.1.2 Apparition de nouveaux objets

Il reste donc, pour compléter cette phase d'initialisation de pistes, à indiquer au filtre la présence de nouvel objet. En effet, l'approche doit automatiquement s'adapter à la gestion non supervisée d'un nombre inconnu de nouveaux objets. Pour cela, on utilise l'accumulateur de la mesure Z_t pour calculer l'innovation associée I_t :

$$I_t = Z_t - \sum_{j=1}^{J_t} \tilde{Z}_t^j \quad (6.24)$$

En absence de nouveaux véhicules, $E(I_t) \rightarrow E(\nu_t)$. I suit la loi de ν . En présence de nouveaux objets, des motifs triangulaires subsistent dans I : l'hypothèse gaussienne n'est plus vérifiée. Plusieurs solutions existent alors pour vérifier la conservation de l'hypothèse gaussienne et donc l'absence de nouveaux objets, comme par exemple un test du khi-deux [BSL93].

Pour ce processus de gestion de pistes, il est également nécessaire de conserver dans I_t uniquement les motifs représentatifs des objets évoluant dans la zone d'intérêt (route). Ainsi, une restriction à la zone d'étude est appliquée. Une procédure spécifique pour différencier les impacts télémétriques appartenant à la route de ceux ne représentant pas des objets d'intérêt a été développée dans le cadre de ces travaux (annexe B). Avec les données réelles, l'utilisation conjointe des données GPS du véhicule porteur du capteur et des données vectorielles du parcours routier emprunté permet d'aboutir à un filtrage suffisant des impacts laser représentatifs des objets présents dans la zone d'observation.

Nous avons choisi dans notre cas une solution basée sur le modèle d'objet suivi *a priori* :

- un critère trivial de nombre de points appartenant à un même segment résiduel est d'abord utilisé. En raison de l'influence de la distance entre le capteur et le nouvel objet, nous avons volontairement choisi de fixer cette valeur à 1 (ce qui correspond alors à 3 points appartenant à un même segment). Des objets situés à longue distance du capteur sont en effet représentés par peu de mesures.
- Pour ne pas conduire à une création excessive de pistes (notamment en cas d'objet proche du capteur), ce critère est combiné à un second seuil th_s représentant la longueur minimale du segment correspondant et fixé selon l'application. Une phase d'extraction est alors nécessaire en utilisant le détecteur SIP et uniquement les segments de tailles significatives sont conservés. Une étape de modélisation basée sur cette segmentation est effectuée pour fournir la position des nouveaux objets.

Si ces critères sont remplis, alors le filtre est initialisé avec la procédure décrite ci-dessus (initialisation des états des particules basée sur un maillage de l'espace d'état).

6.6.2 Arrêt de pistes

Les méthodes classiques de suivi avec détection et association permettent de fournir un cadre rigoureux en cas d'arrêt de pistes. En effet, celle-ci intervient à partir du moment où une piste existante n'est plus associée avec une mesure de l'instant courant. Notre méthode, telle qu'elle est conçue jusqu'à présent, ne prend pas en compte cette spécificité. En effet, la phase de pondération a toujours lieu puisque le modèle d'objet intégré au filtre conditionne la sélection de la zone d'intérêt dans l'accumulateur qui, en l'état actuel, existe toujours. Mais cette zone d'intérêt peut ne plus représenter un objet réellement présent (un objet peut par exemple disparaître spontanément par défaillance du capteur, l'accumulateur de la mesure sera alors nul).

Il a donc été conçu une technique analogue à celles utilisées dans les méthodes classiques de suivi afin de pouvoir clore une piste. L'idée est d'utiliser l'accumulateur de la mesure restreint à la zone d'intérêt (\tilde{Z}_t^j) comme indicateur d'arrêt de piste. La notion d'horizon temporel est une nouvelle fois utilisée (§5.3.2.2) afin de gérer à la fois les éventuelles défaillances ponctuelles du télémètre et des accumulateurs très perturbés. Cette valeur indique en fait le nombre d'itérations successives pendant lesquelles le filtre local est maintenu. La technique consiste à tester si la somme des valeurs de la fonction cumulative \tilde{Z}_t^j est inférieure à un seuil th_{CF} , et dans ce cas on considère que l'objet suivi n'est pas présent dans l'environnement mesuré.

Dans ce cas précis, si l'horizon temporel n'est pas nul, alors on considère que l'objet existe toujours sous la notion de « prédiction pure ». Son état estimé à l'instant t est l'état prédit, les particules sont conservées et l'horizon temporel est décrémenté. Si la valeur de l'horizon temporel est nulle, alors la piste est arrêtée à l'instant $(t - 1)$, et le filtre local est libéré.

La notion d'horizon temporel joue un rôle important dans les méthodes de suivi avec détection, puisque les cas de non-association entre une piste existante et l'ensemble des mesures sont plus réguliers (erreurs de segmentation des données télémétriques, mauvaise modélisation des objets, erreurs d'association). Notre méthode présente l'intérêt de travailler directement avec les accumulateurs. Un accumulateur ne représentant pas un objet signifie dans ce cas qu'aucun impact télémétrique ne représente l'objet. Cette situation est donc représentative soit d'une disparition d'un objet du champ de vision, soit d'une défaillance complète du capteur télémétrique.

À noter que ce processus d'arrêt de pistes permet également de gérer automatiquement les cas de divergence du filtre.

6.7 Gestion de l'occultation des objets dans le calcul de la distance capteur-objet.

La détermination des indices pour le calcul de la distance entre le capteur et l'objet est basée sur l'accumulateur sans bruit de l'état prédit. Il peut exister des cas où la donnée télémétrique correspondante n'est pas représentative de l'objet suivi en raison de défaillances du capteur. Mais il existe une configuration de placement des objets dans la scène qui produit ce phénomène de manière plus

régulière, à savoir l'occultation partielle qui entraîne une modification du taux de visibilité de l'objet sur l'une ou les deux faces. La figure 6.7(a) illustre cette configuration. Dans ce cas, l'accumulateur de la mesure représente uniquement la partie visible (fig. 6.7(b)). Par contre, la détermination des indices de pondération passe par l'analyse de l'accumulateur obtenu par reconstruction de la scène sans bruit par placement unique de l'objet suivi. Ainsi, le modèle d'objet étant de taille fixe, l'accumulateur sans bruit (fig. 6.7(b)) représente un objet qui serait de taille proche de celle du modèle. L'indice du pic de l'accumulateur théorique ne correspond plus à un impact de l'objet effectivement suivi.

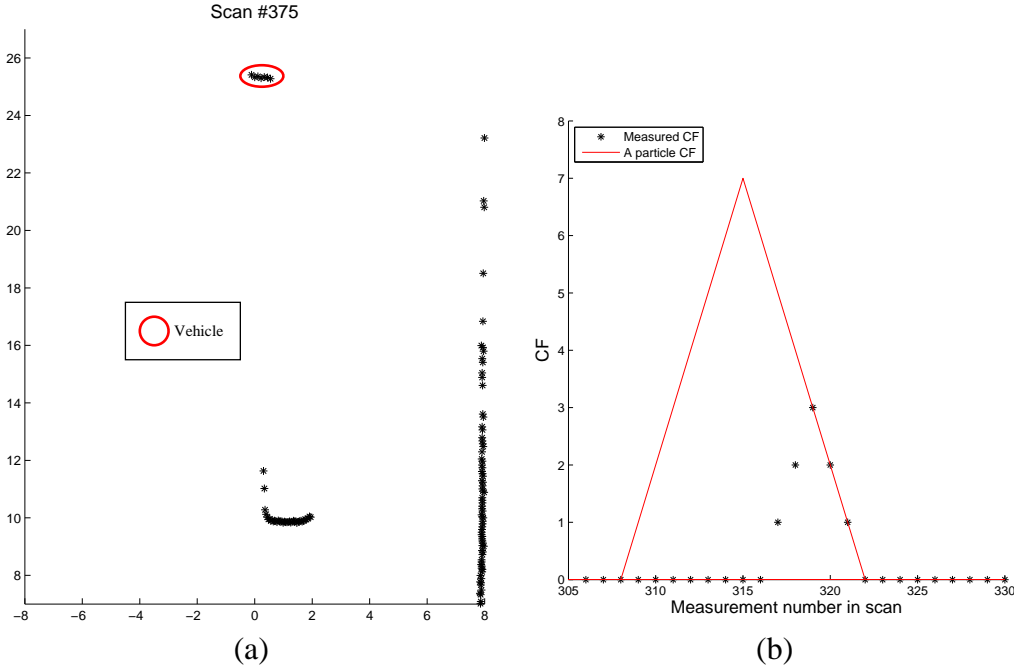


FIGURE 6.7 – (a) Scène étudiée avec un objet partiellement occulté (cercle) (b) Accumulateur mesuré restreint à la zone d'intérêt du véhicule occulté (croix) et accumulateur d'une particule (triangle)

Afin de ne pas calculer de distances entre des impacts qui ne représenteraient pas le même objet, un test basé sur une distance euclidienne est proposé. Notons w_1^j un indice d'impact pour le calcul de la distance capteur-objet estimé par l'accumulateur sans bruit de l'objet prédit. Notons $(x_{t|t-1}^j, y_{t|t-1}^j)$ les coordonnées du centre de gravité de l'objet j après la phase de prédiction. La distance maximale entre un impact sur une face de l'objet et le centre de gravité est atteinte lorsque l'impact est situé sur le coin (et donc la distance vaut une diagonale de véhicule $diag_veh$). Le test 6.25 est alors effectué.

$$d_{test} = \left\| \begin{pmatrix} x_{t|t-1}^j \\ y_{t|t-1}^j \end{pmatrix} - \begin{pmatrix} \rho_t^m(u_1^j) \cdot \cos(\theta_{u_1^j}) \\ \rho_t^m(u_1^j) \cdot \sin(\theta_{u_1^j}) \end{pmatrix} \right\|_2 > (1 + \epsilon) diag_veh \quad (6.25)$$

Si le test est vérifié, alors la distance capteur-objet n'est pas calculée afin de ne pas introduire de biais dans la phase de pondération.

Finalement, la figure 6.8 illustre une itération de la méthode de suivi sans détection que nous avons développée.

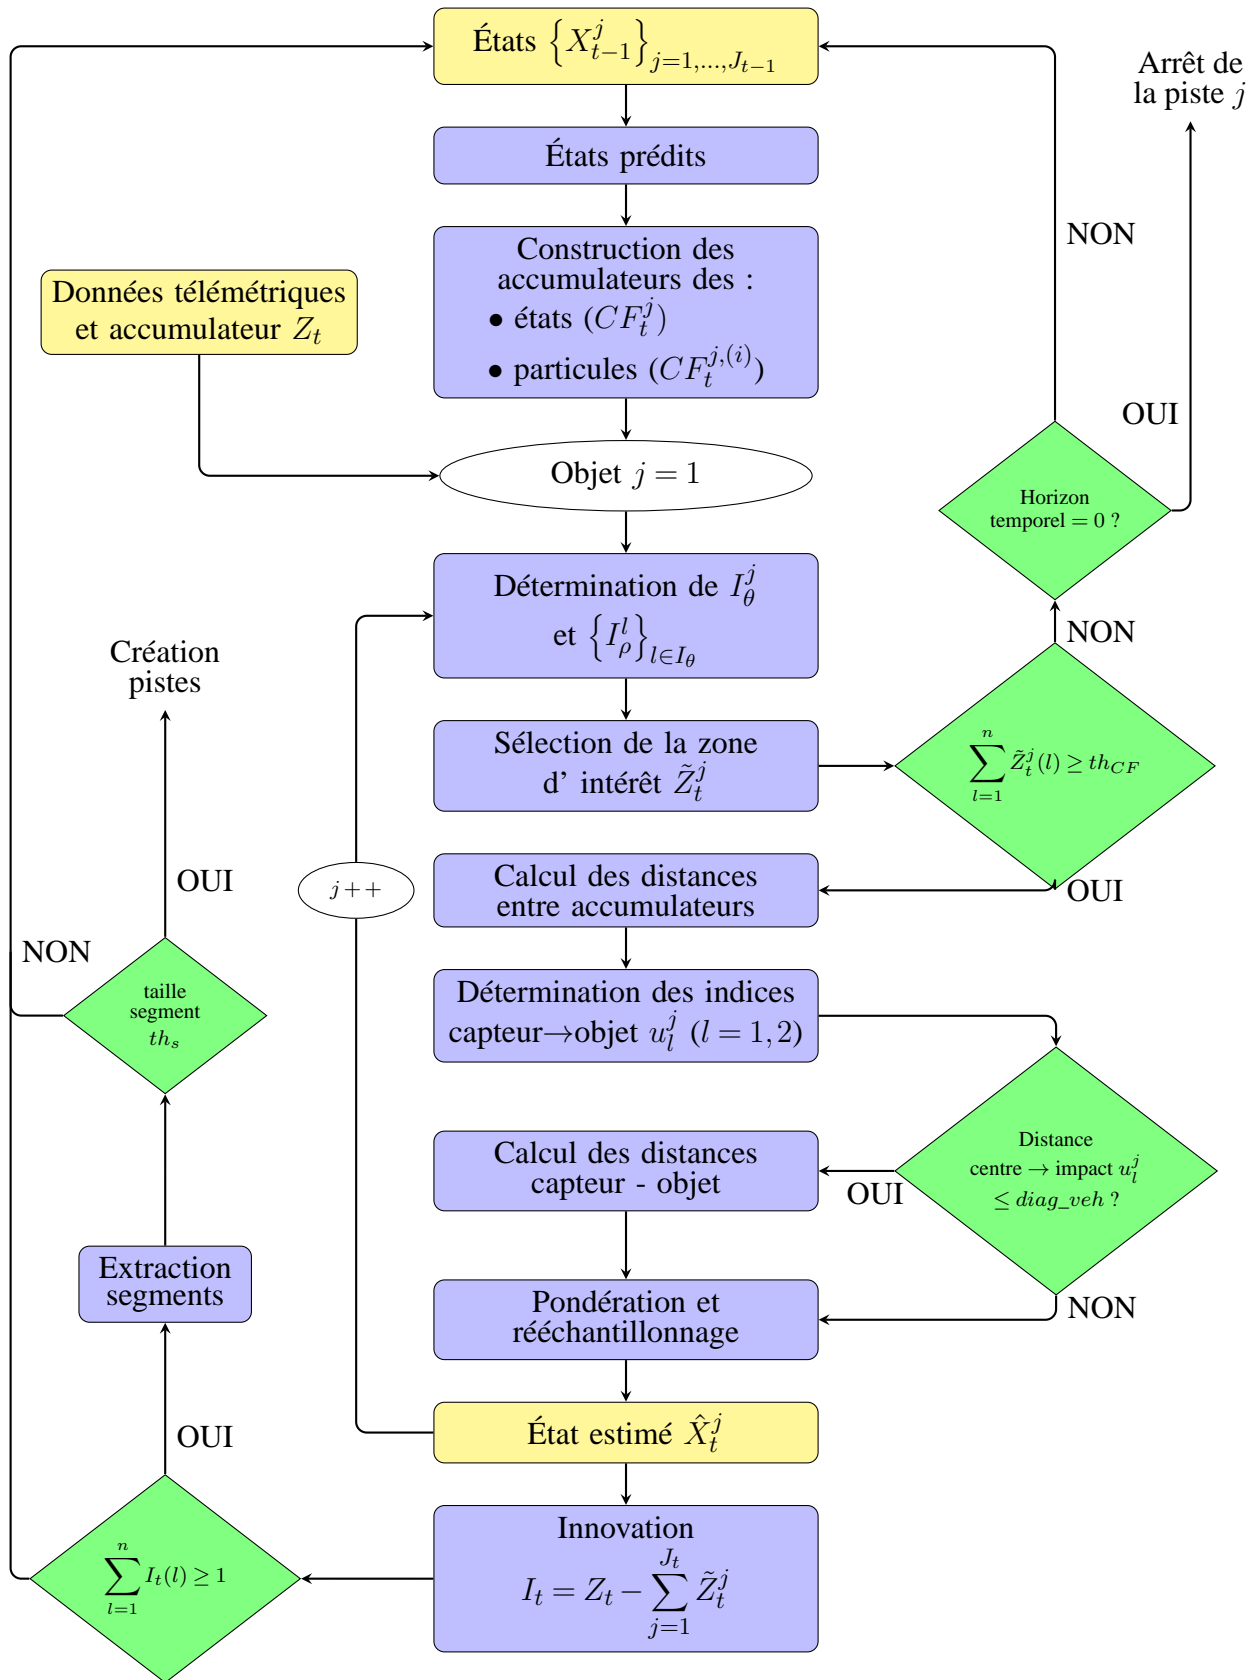


FIGURE 6.8 – Représentation schématique d'une itération de l'algorithme implémentant la méthode de suivi sans détecteur IP-SMC

6.8 Expérimentations

6.8.1 Données synthétiques

6.8.1.1 Protocole d'évaluation

La méthode a d'abord été évaluée et comparée à une approche classique utilisant un détecteur (le filtre SM-SMC-JPDA) et à la méthode PHD avec détecteurs (SIP-SMC-PHD et SM-SMC-PHD). Le scénario utilisé pour la comparaison est un scénario dans lequel 5 véhicules évoluent pendant 50 secondes dans toutes les configurations possibles : apparition, disparition, occultation.

Les critères d'évaluation sont identiques à ceux utilisés dans l'évaluation des méthodes de suivi avec détection (§5.3.3.1.2) :

La plupart des paramètres sont communs aux expérimentations du §5.3.3.1.3, à l'exception :

- du nombre de particules par cible : $N_p = 10000$
- des statistiques du bruit de dynamique : $\sigma_{\gamma_x}^2 = 0.30\text{m/s}^{-2}$ et $\sigma_{\gamma_y}^2 = 0.60\text{m/s}^{-2}$

Les méthodes basées sur le PHD ont quelques paramètres spécifiques, à savoir :

- la probabilité de survie d'une piste : $P_S = 0.95$
- la densité du clutter qui suit une loi de Poisson de paramètre 3 impacts par scan
- le nombre de particules exploratrices : $N_t^b = 1000$

La méthode IP-SMC possède aussi des paramètres spécifiques liés aux accumulateurs :

- les statistiques pour l'étape de pondération fixées à $\sigma_\rho = 0.03\text{m}$ et $\sigma_\nu = 1$;
- le seuil pour la décision de non-pondération d'un objet suivi, fixé à $th_{CF} = 2$;
- la taille minimale pour la création de pistes, fixée à $larg_veh/2$.

6.8.1.2 Résultats comparatifs avec les méthodes SIP-SMC-PHD, SM-SMC-PHD et SM-SMC-JPDA

Les figures 6.9 et 6.10 montrent l'intérêt de travailler directement avec l'accumulateur et donc avec les données télémétriques sans passer par l'étape de détection. En effet, le processus de suivi est plus stable. La méthode proposée permet de réduire considérablement le taux de fausse alarme. Sur 5 pistes théoriquement existantes, IP-SMC crée en effet 5 pistes alors que le filtre SIP-SMC-PHD en crée trois fois plus (17). La continuité des pistes est donc plus longtemps maintenue avec l'approche IP-SMC, alors qu'elle est parfois interrompue pour la méthode avec détecteur (itération 400 par exemple), ce qui engendre plusieurs tentatives pour gérer l'apparition d'objets (itération 220 sur la fig. 6.10) qui sont en réalité un objet déjà existant. Les erreurs de détection, les mauvaises modélisations et les erreurs dans l'étape de séparabilité des modes perturbent le suivi pour une méthode classique de suivi d'objets, même quand celle-ci est implantée avec le détecteur SIP, plus performant que SM (figures 6.10(a)-(d)). Les changements de voie du véhicule porteur (entre les itérations 70-160 et 370-460) ne perturbent pas notre méthode IP-SMC, notamment visible sur l'estimation de l'orientation.

Cette meilleure continuité des pistes induit alors une meilleure précision d'estimation (table 6.1),

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
Filtre IP-SMC	0.031	0.066	0.125	1.530	0.059	5
Filtre SIP-SMC-PHD	0.068	0.124	0.130	1.854	0.111	17
Filtre SM-SMC-PHD	0.159	0.218	0.201	1.967	0.136	36
Filtre SM-SMC-JPDA	0.514	0.371	0.223	1.988	0.179	48

TABLE 6.1 – *Écart-type des erreurs d'estimation pour les différents filtres, distance OSPA-T moyenne et cardinalité pour une précision de mesure $\sigma_\rho = 0.03m$*

puisque une piste créée a besoin d'un temps de convergence pendant lequel l'estimation de l'état de l'objet est moins précise. Si l'on compare notre méthode IP-SMC avec une approche classique SM-SMC-JPDA, la précision d'estimation est nettement améliorée quelles que soient les composantes considérées : l'estimation de position est 16 fois plus précise, celle de la vitesse plus de 5 fois. Le nombre de pistes créées par SM-SMC-JPDA (48) implique de fortes perturbations dans le processus de suivi.

L'apport du détecteur SIP a permis une amélioration des statistiques d'estimations (comparaison entre les filtres SM-SMC-JPDA et SIP-SMC-PHD). La méthode développée sans détecteur permet d'aller plus loin dans l'amélioration des statistiques : un facteur 2 existe avec SIP-SMC-PHD sur les estimations de la position et de la vitesse, l'apport étant un peu plus faible sur celles de l'accélération et l'orientation. IP-SMC estime la position des objets avec un écart-type de l'erreur de 3cm, de l'ordre de l'écart-type du bruit de mesure sur les impacts (σ_ρ). L'approche SM-SMC-PHD permet, en terme de résultats, de tirer avantage du cadre de travail multi-cibles PHD comparé au JPDA.

Les cardinalités estimées par les méthodes IP-SMC et SIP-SMC-PHD sont indiquées sur les figures 6.11(b)-(c). Le suivi sans détection que nous avons développé permet de déterminer exactement le nombre d'objets à chaque instant en régime nominal du filtre. Ces figures font apparaître un léger retard à la détection de nouvelles cibles (apparition proche du capteur). Ceci s'explique par le seuil choisi pour la création de nouvelles pistes choisi volontairement élevé dans notre application pour éviter une divergence rapide du filtre en cas de mauvaise initialisation, pour toutes les méthodes. Le filtre SIP-SMC-PHD présente quelques erreurs de cardinalité, dues généralement à des erreurs de modélisation à l'issue de la phase de détection. On peut aussi remarquer que la méthode sans détecteur permet de maintenir plus longtemps la durée d'estimation des pistes (itérations 160 et 220) lorsqu'un objet disparaît du champ de vision du capteur. Ceci s'explique car IP-SMC travaille directement avec l'accumulateur, et donc les données télémétriques. Si au moins th_{CF} impacts sont alignés, alors l'estimation de l'état est toujours possible, contrairement aux méthodes avec détection qui nécessitent de détecter un segment suffisamment long avant de procéder à la phase de modélisation.

Enfin, la distance OSPA-T (fig.6.11(a)) combinant la précision d'estimation des paramètres cinématiques et la cardinalité confirme le bénéfice apporté par une approche de suivi d'objets sans détection. La valeur moyenne de la distance OSPA-T est deux fois plus faible pour IP-SMC que pour SIP-SMC-PHD et trois fois plus faible pour SM-SMC-JPDA (SM-SMC-PHD étant à un niveau intermédiaire).




FIGURE 6.9 – Estimations de la norme des composantes pour la méthode proposée : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)


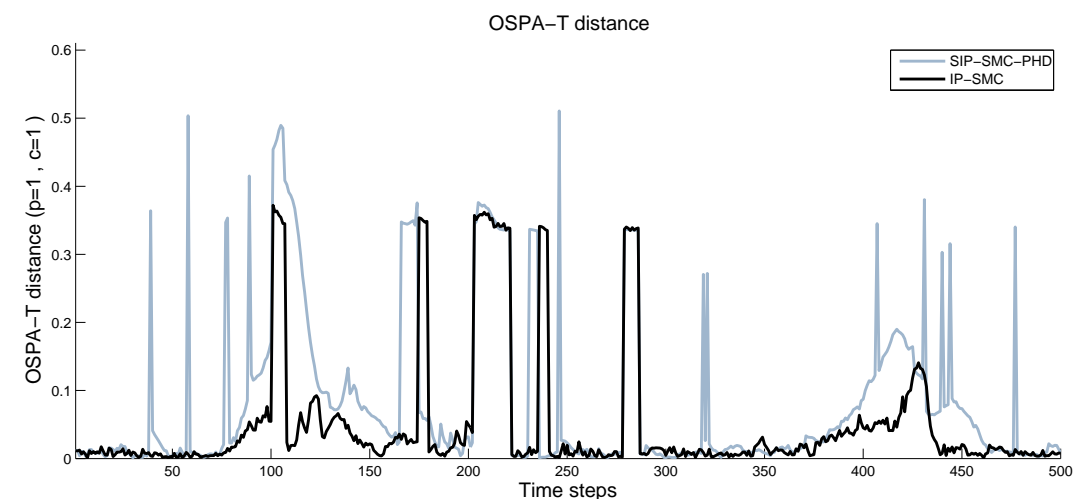




FIGURE 6.10 – Estimations de la norme des composantes pour le SIP-SMC-PHD : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes théoriques (points noirs)



(a)



(b)



(c)

FIGURE 6.11 – (a) Distance OSPA-T à chaque itération pour IP-SMC (noir) et SIP-SMC-PHD (gris) (b) Cardinalité estimée IP-SMC (trait pointillé) et cardinalité théorique (trait plein) (c) Cardinalité estimée SIP-SMC-PHD

6.8.1.3 Robustesse au bruit de mesure

Les quatre méthodes sont évaluées sur un scénario dans lequel l'écart-type du bruit de mesure du capteur télémétrique est plus élevé ($\sigma_\rho = 0.1\text{m}$ pour le scénario présenté dans la section 5.3.3.1.4).

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
Méthode proposée	0.036	0.111	0.130	0.462	0.085	4
Filtre SIP-SMC-PHD	0.071	0.220	0.284	0.607	0.142	17
Filtre SM-SMC-PHD	0.158	0.266	0.275	0.884	0.181	34
Filtre SM-SMC-JPDA	0.658	0.481	0.234	1.523	0.271	64

TABLE 6.2 – Écart-type des erreurs d'estimation pour les différents filtres, distance OSPA-T moyenne et cardinalité pour une précision de mesure $\sigma_\rho = 0.1\text{m}$

Les mêmes résultats relatifs sont constatés entre une méthode classique avec un détecteur SM, l'approche PHD avec le détecteur SIP ou SM et la méthode proposée qui travaille directement avec les données télémétriques. IP-SMC crée uniquement 4 pistes (sur 4 théoriques) et perturbe donc beaucoup moins le processus de suivi que les trois méthodes avec détecteur, ce que confirme les statistiques de précision d'estimation. La distance OSPA-T confirme les différents gains apportés par la méthode IP-SMC.

6.8.2 Données réelles

La méthode IP-SMC a été validée sur les mêmes données réelles, avec les paramètres pour les méthodes avec détection identiques à ceux précédemment utilisés (section 5.3.3.2). Les paramètres spécifiques à la méthode sans détecteur sont les mêmes que ceux utilisés pour les données synthétiques (section 6.8.1.1). L'approche SM-SMC-PHD n'est pas présentée en raison des conclusions tirées sur les tests synthétiques.

Les trajectoires pour chaque composante sont affichées sur les figures 6.12 (méthode IP-SMC) et 6.13 (SIP-SMC-PHD). Il apparaît clairement une amélioration de la continuité du suivi des objets, notamment dans le cas de données présentant un nombre important d'outliers entre les itérations 50 et 100. La méthode IP-SMC ne dépend en effet plus de la phase de segmentation qui est alors très délicate et qui perturbe le suivi pour SIP-SMC-PHD. La continuité des pistes est donc plus assurée avec l'approche IP-SMC et il y a moins de phases de créations de pistes. Les trajectoires présentant l'estimation de l'orientation des objets montrent des courbes moins perturbées lorsque la méthode de suivi n'est pas conditionnée par un détecteur.

La table 6.3 indique le nombre de pistes créées sur l'ensemble de la séquence étudiée. Les deux méthodes avec détection créent plus de pistes que la méthode IP-SMC, qui fournit exactement le nombre de pistes attendues. Le nombre élevé de points aberrants dans les données entre les itérations 50 et 100 ne perturbent pas le processus en raison de l'horizon temporel introduit, et aucune piste additionnelle n'est donc créée.




FIGURE 6.12 – Estimations de la norme des composantes pour IP-SMC en ligne droite : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente. Les détections SIP sont affichées en points verts (à titre indicatif).

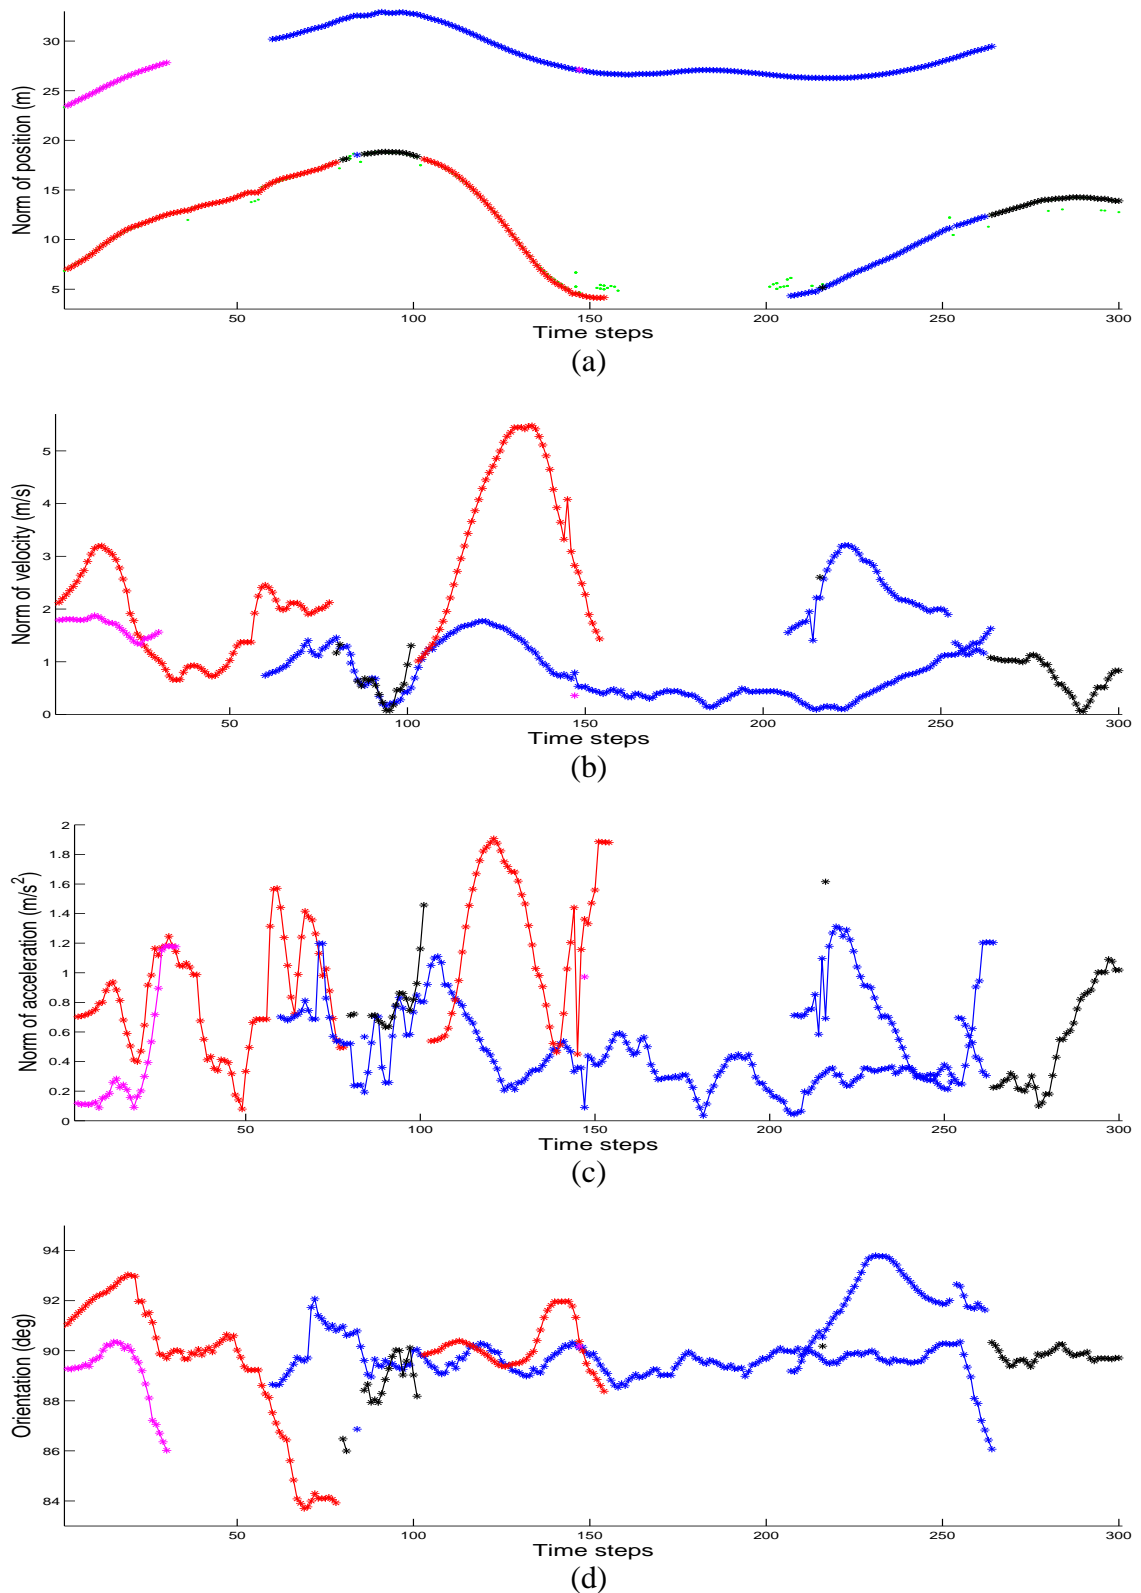


FIGURE 6.13 – Estimations de la norme des composantes pour SIP-SMC-PHD en ligne droite : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente. Les détections SIP sont affichées en points verts.

Méthode	nombre de pistes créées (4 théoriques)
IP-SMC	4
SIP-SMC-PHD	12
SM-SMC-JPDA	8

TABLE 6.3 – Nombre total de pistes créées sur une séquence réelle pour les méthodes IP-SMC, SIP-SMC-PHD et SM-SMC-JPDA




FIGURE 6.14 – (a) Cardinalité estimée IP-SMC (rouge) et cardinalité théorique (noir) (b) Cardinalité estimée SIP-SMC-PHD (bleu)

La méthode IP-SMC estime mieux la cardinalité (tab. 6.14). Une nouvelle fois, les seules erreurs de cardinalité sont des retards à la détection de nouvelles pistes, volontaires pour assurer une meilleure convergence. Le même phénomène apparaît pour la destruction de pistes grâce à l'horizon temporel, en raison d'objets qui sont toujours estimés lorsqu'ils sortent du champ de vision. Dès que le segment est trop petit pour l'approche SIP-SMC-PHD, celle-ci n'estime plus l'état des objets, ce qui explique pourquoi le temps de suivi est plus court. Cette situation peut alors être avantageuse dans de tels systèmes de surveillance où un objet se trouve à proximité du véhicule porteur même s'il n'est plus directement dans le champ de vision du capteur télémétrique. L'un des avantages apportés par la notion d'horizon temporel est de palier les défaillances momentanées du télémètre (itération 78), et donc de ne pas clore la piste en l'initialisant de nouveau à l'instant suivant, assurant ainsi une continuité dans l'estimation des paramètres cinématiques des objets.

Pour terminer, nous avons reconstruit le modèle estimé par les trois méthodes pour différentes itérations présentant des configurations remarquables. Les détections issues de la phase de segmentation et de modélisation sont affichées en carré rouge, et le modèle reconstruit basé sur l'estimation des paramètres par chaque méthode apparaît sous la forme d'un rectangle bleu :

- Scan #273 (fig.6.15(a)) : l'objet suivi est uniquement visible par sa face arrière. La forme de la carrosserie du véhicule explique la distribution particulière des données télémétriques. Le modèle d'objet choisi d'adapte parfaitement aux impacts laser pour la méthode IP-SMC. La segmentation délicate pour ce genre de données amène les deux méthodes avec détection à fournir une mauvaise estimation du centre de gravité du véhicule.

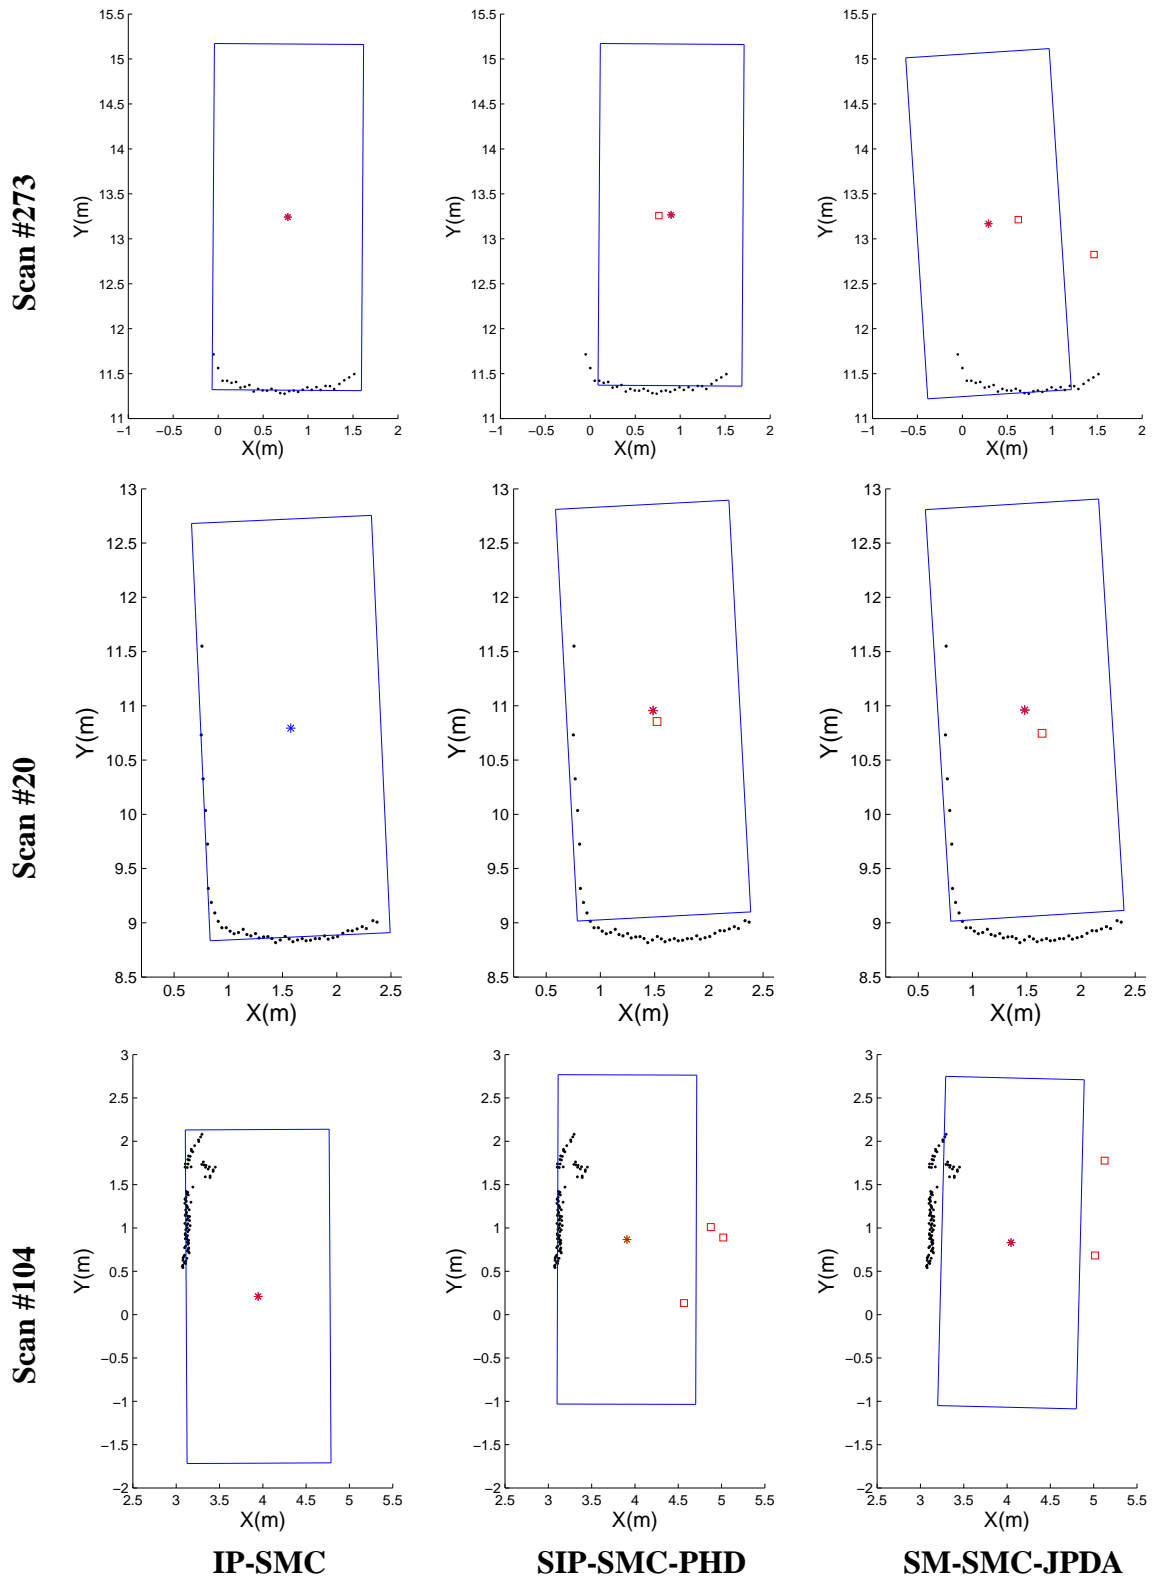


FIGURE 6.15 – Reconstruction des véhicules estimés (rectangles) pour les trois filtres et mesures issues du détecteur dans différentes configurations

- Scan #20 (fig.6.15(b)) : les deux faces du véhicule sont visibles par le capteur. Une nouvelle fois, la méthode IP-SMC permet d'ajuster de manière optimale le modèle rectangulaire aux données. En effet, le nombre élevé de points sur la face arrière permet une première sélection des particules les mieux localisées, tandis que l'ajustement horizontal s'affine par le second côté visible. Les deux méthodes avec détection ne permettent pas d'aboutir à ce niveau de modélisation.
- Scan #104 (fig.6.15(c)) : il s'agit d'un cas particulier où le véhicule apparaît en doublant le véhicule porteur. Seule une partie de la longueur de l'objet est donc visible. Les données sont extrêmement bruitées, en raison notamment de la roue, et peuvent être mis en correspondance avec le phénomène de clutter. L'approche IP-SMC permet, une nouvelle fois, un ajustement optimal du modèle en tirant profit la distribution des données. Les deux méthodes avec détection se trouvent dans un cas critique. En raison de la visibilité partielle du véhicule, la segmentation est perturbée et induit une mauvaise modélisation provoquant plusieurs mesures aberrantes.

Il est remarquable de noter que la méthode est robuste aux dimensions du modèle rectangulaire. En effet, elles ont été fixées à une valeur de taille moyenne d'un véhicule. Bien que les objets suivis soient de modèles et marques différents, notre méthode permet d'ajuster de la meilleure manière possible un modèle rectangulaire, même quand la surface visible est légèrement courbée (pare-choc des véhicules). Il s'agit d'un atout important pour notre approche IP-SMC.

6.9 Conclusion

Ce chapitre a permis de présenter une nouvelle approche de suivi d'objets dans des données distribuées. En intégrant directement le modèle de forme suivi dans le filtre, cette méthode permet de réaliser conjointement la détection et le suivi d'objets multiples, appliquée ici à un suivi de véhicules. L'introduction du modèle géométrique dans le filtre passe par une mise en forme particulière des données télémétriques en prenant en compte leur distribution. L'accumulateur du détecteur SIP que nous avons introduit précédemment est alors un processus d'agrégation exploitable. Le suivi des objets peut ainsi être représenté en partie par le suivi de leur accumulateur au cours du temps. En ajoutant la notion de distance entre le capteur et l'objet, il est alors possible de caractériser complètement un objet par cette nouvelle représentation des données distribuées.

Notre méthode présente les avantages des méthodes de type « track-before-detect ». En faisant totalement abstraction de la phase de détection, le risque de mauvaise estimation est considérablement diminué (réduction du nombre de fausses pistes, de non-détections, de mauvaises modélisations ou associations). La prise en compte de l'ensemble des données télémétriques appartenant à un objet permet aussi d'obtenir une plus grande robustesse aux données très bruitées et aux outliers. L'évaluation faite sur des données synthétiques et réelles valident les gains de la méthode en terme de précision d'estimation, de cardinalité dans la scène mais aussi de continuité dans les trajectoires des objets. Ce dernier point induit un meilleur comportement du système global de suivi en diminuant les

perturbations provoquées par les phases d'initialisation.

D'un point de vue théorique, les non-linéarités de l'équation d'observation ont été gérées par les méthodes de Monte Carlo séquentielles. La phase de pondération du filtre particulaire est le point complexe de l'approche. Elle est construite autour de deux distances, l'une basée sur la similarité entre les accumulateurs et la seconde évaluant l'écart le capteur et l'objet suivi. Chaque objet est suivi de manière individuelle, en implémentant parallèlement autant de filtres qu'il y a d'objets. Un aspect de gestion de pistes a également été proposé par analyse des différents accumulateurs : celui de la mesure de la scène et ceux reconstruits à partir du placement de chacun des objets déjà suivis. Il est ainsi possible d'initialiser et de terminer automatiquement une piste.

La méthode a été formalisée et développée dans le cadre de notre application de suivi de véhicules, et donc d'objets rectangulaires de taille fixe. Celle-ci est cependant généralisable en une approche quelconque de suivi d'objets polyédriques quelconques dans des données distribuées en minimisant le nombre d'ajustements nécessaires :

- le nombre de faces visibles des objets à suivre conditionne le nombre de motifs triangulaires dans l'accumulateur. Ainsi, une simple modification de la distance entre accumulateurs serait à mettre en œuvre afin de caractériser complètement le type d'objets suivis. La distance entre le capteur et l'objet est, quant à elle, utilisable en l'état.
- même si notre méthode a prouvé sa robustesse face à la taille fixée du modèle, l'hypothèse forte de taille fixe peut également être levée. En effet, une approche multi-modèles pourrait être développée en regroupant les différents types d'objets dans plusieurs classes (voitures petite gamme, moyenne gamme, camion, ...) qui aboutiraient à des représentations sous formes d'accumulateurs différents. Une seconde solution pourrait aussi être basée sur une phase d'identification préalable.

Chapitre 7

Suivi de cibles distribuées par approche IP-SMC dans un cadre PHD

7.1 Introduction

La méthode IP-SMC développée dans le chapitre 6 est une approche conjointe de détection et de suivi de cibles distribuées. Le suivi est géré indépendamment pour chaque objet. L'accumulateur complet de l'acquisition est en effet scindé de manière adaptative selon le nombre d'objets suivis à l'instant précédent en plusieurs accumulateurs. L'approche est donc constituée de plusieurs filtres locaux réalisant chacun le suivi mono-objet.

On se propose dans ce chapitre de généraliser notre méthode IP-SMC dans un cadre PHD (approche IP-SMC-PHD) [FLN13a, FLN13b]. Celle-ci entre dans le cadre des méthodes ETT-PHD [Mah09, GLO12] en proposant une approche différente en considérant un processus d'aggrégation des données télémétriques. Tous les objets sont conjointement suivis par considération de la multi-modalité de la densité de probabilité *a posteriori*. La totalité des états des objets sont regroupés dans un RFS dont la cardinalité est estimée à chaque instant. À partir de cette estimation, une étape de séparation des modes est appliquée afin d'extraire l'état estimé de chaque objet. L'un des avantages du PHD est l'exploration, dans le filtre, de l'espace d'état à chaque instant d'estimation. Celle-ci peut alors aboutir à une initialisation automatique des objets apparaissant dans le champ de vision du capteur. Cette phase d'exploration est conditionnée selon l'application finale (§5.4.2.1). Dans le cadre de ces travaux, il est nécessaire de concevoir des techniques spécifiques d'exploration qui prennent en compte la spécificité des mesures utilisées, qui sont ici représentées sous la forme d'un accumulateur.

L'une des difficultés majeures de l'approche PHD est la phase de correction des états qui s'effectue de manière globale pour tous les objets. L'accumulateur constitue le RFS des mesures et il est utilisé pour la mise à jour. La correction dans la méthode IP-SMC a été développée par la définition d'une vraisemblance basée sur l'accumulateur restreint aux objets d'intérêt et la distance capteur-objet. Dans le cadre PHD, il est indispensable de redéfinir la vraisemblance puisqu'il est impossible d'implémenter exactement les mêmes outils. En effet, l'accumulateur global représente l'ensemble

des objets présents dans la zone d'observation et il existe une trop forte discrimination entre les accumulateurs pour une utilisation identique à celle faite pour l'approche IP-SMC.

L'architecture du filtre de suivi multi-objets basée sur l'approche PHD est dans un premier temps explicitée (IP-SMC-PHD). Elle reprend en partie les étapes d'un filtre PHD développé en 5.4 et les techniques utilisées dans un suivi sans détection présentées dans le chapitre 6. Les solutions construites pour la gestion du RFS des mesures (accumulateur) sont détaillées, notamment en terme de découpage de l'accumulateur de la scène et du placement des particules exploratrices. La méthode IP-SMC-PHD est ensuite évaluée sur des données synthétiques comparativement aux méthodes classiques avec détecteur (SIP-SMC-PHD et SM-SMC-JPDA). Une étude avec la méthode sans détection IP-SMC est également présentée.

On se propose également dans ce chapitre d'introduire une étape supplémentaire vers la fusion de données en évaluant la méthode IP-SMC-PHD sur des données réelles dans lesquelles des mesures provenant de centrales inertielles sont disponibles afin de montrer l'apport sur la qualité du suivi. La centrale inertielle est en effet un capteur utilisé [DEMG12] pour améliorer la robustesse d'un système de perception dans des conditions de variabilité de dynamiques plus forte (virages à rayon de courbure faible, changements de voie plus rapides).

7.2 Résolution du problème de suivi

7.2.1 Modèles

La modélisation de la dynamique des objets est toujours la même. Elle est basée sur un modèle cinématique d'ordre 3 et présentée dans le paragraphe 6.2.

Le modèle d'observation utilisé est également présenté de manière simplifiée en 6.3.1 :

$$Z_t = H(X_t) + \nu_t = CF_t + \nu_t \quad (7.1)$$

où ν_t est un bruit blanc gaussien n -dimensionnel de moyenne nulle et de covariance $R = \sigma_\nu^2 I_n$. La fonction d'observation H permet de déterminer l'ensemble des impacts télémétriques puis de calculer l'accumulateur.

Dans ce chapitre, on se propose d'inclure des données inertielles (lorsqu'elles sont disponibles) et donc de prendre en compte la rotation du repère mobile (fig. 5.1) précédemment négligée. L'orientation des objets observés par le télémètre est déterminée grâce à la loi de composition des vitesses :

$$\vec{V}_M^{R^W} = \vec{V}_M^{R'} + \vec{V}_{O'}^{R^W} + \vec{\Omega} \wedge \overrightarrow{O'M}^{R'} \quad (7.2)$$

On rappelle que $\vec{\Omega}$ est la vitesse angulaire du repère lié au porteur par rapport au repère monde, $\vec{V}_{O'}^{R^W}$ la vitesse linéaire du porteur par rapport au repère monde, $\overrightarrow{V}^{eg\delta}$ la vitesse linéaire mesurée du porteur, et $\overrightarrow{O'M}^{R'}$ et $\vec{V}_M^{R'}$ les composantes positions et vitesses de l'objet suivi. Par la nature planaire des mouvements, Ω se réduit à une seule composante (autour de l'axe z) qu'on note ω_t .

L'orientation ψ_t de l'objet, à pi près, est alors donnée à un instant t par :

$$\psi_t = \arctan \left(\frac{v_t^y + \left\| \overrightarrow{V_t^{eg\delta}} \right\| + \omega_t x_t}{v_t^x - \omega_t y_t} \right) \quad (7.3)$$

7.2.2 Architecture du filtre IP-SMC-PHD

Les étapes classiques du filtre PHD, déjà explicitées dans le chapitre 5, sont détaillées pour un suivi sans détecteur que l'on cherche à mettre en œuvre.

1. Initialisation : Dans l'approche PHD, un nuage pondéré de N_{t-1} particules approche la fonction intensité D (éq. 5.36).

2. Évolution des particules existantes : les particules $\left\{ X_{t-1}^{(i)} \right\}_{i=1, \dots, N_{t-1}}$ évoluent dans l'espace d'état et les poids prédits associés sont donnés par l'équation 5.40.

3. Exploration de l'espace d'état : pour $i \in \llbracket N_{t-1} + 1, N_{t-1} + N_t^b \rrbracket$, N_t^b particules sont créées selon la loi $X_t^{(i)} \sim p(\cdot | \mathcal{Z}_t)$. L'objectif est d'initialiser automatiquement les nouvelles cibles de l'espace d'état. Tout comme la méthode PHD avec détection développée (SIP-SMC-PHD), un placement judicieux des particules exploratrices d'état est mis en place (paragraphe 7.3.2). Les poids des particules exploratrices sont donnés par l'équation 5.42.

4. Mise à jour des poids : il s'agit du point clé de la méthode. Les poids des $N_t = N_{t-1} + N_t^b$ particules sont calculés :

$$\forall i \in \llbracket N_{t-1} + 1, N_{t-1} + N_t^b \rrbracket, \omega_t^{(i)} = \left[1 - p_D(X_t^{(i)}) + \sum_{Z \in \mathcal{Z}_t} \frac{p_D(X_t^{(i)}) L_Z(X_t^{(i)})}{\kappa(Z) + C_t(Z)} \right] \omega_{t|t-1}^{(i)} \quad (7.4)$$

avec la constante de normalisation $C_t(Z) = \sum_{j=1}^{N_t} p_D(X_t^{(j)}) L_Z(X_t^{(j)}) \omega_{t|t-1}^{(j)}$. Le calcul de la vraisemblance $L_Z(X_t^{(i)})$ des particules se fait alors de manière analogue à celle calculée pour la méthode IP-SMC :

$$L_Z(X_t^{(i)}) = -\frac{\log(D_{CF}(X_t^{(i)}))}{2\sigma_\nu^2} - \text{card}(\mathcal{I}_1 \cup \mathcal{I}_2) \log(\sigma_\nu \sqrt{2\pi}) - \frac{D_\rho(X_t^{(i)})}{2\sigma_\rho^2} - n_s \log(\sigma_\rho \sqrt{2\pi}) \quad (7.5)$$

où

- $D_{CF}(X_t^{(i)})$ est la distance entre l'accumulateur de la particule et l'accumulateur de la mesure ;
- $\mathcal{I}_1, \mathcal{I}_2$ sont les intervalles sur lesquels la distance D_{CF} est calculée ;
- $D_\rho(X_t^{(i)})$ est la distance entre le capteur et la particule i ;
- n_s est le nombre de face utilisées pour le calcul de la distance D_ρ .

Contrairement à la méthode IP-SMC, le calcul des deux distances doit s'effectuer entre les mesures

du RFS et l'ensemble des particules. Le RFS des mesures est pour le moment uniquement constitué de la scène télémétrique complète perçue par le capteur (et l'accumulateur correspondant). La détermination des zones de pondération ne peut donc être réutilisée à l'identique, le nuage particulaire n'étant plus restreint à un seul objet. Les différents intervalles déterminés de cette façon ne permettront pas d'aboutir à une discrimination satisfaisante des particules. Il est ainsi nécessaire d'adapter le calcul de ces distances dans ce cadre spécifique d'une gestion multi-objets globale (§7.3.1).

5. Rééchantillonnage et estimation des états : ces deux étapes sont exactement identiques à celles développées pour la méthode SIP-SMC-PHD (§5.4.1.4 et §5.4.1.5). Les outils additionnels de vérification de l'étape de séparation des modes sont également utilisées (§5.4.3). La trajectoire est construite en utilisant une technique d'indexation des particules (§5.4.2.2).

7.3 Mise en œuvre de la méthode IP-SMC dans le cadre de l'approche PHD

7.3.1 Constitution du RFS des observations pour la pondération

L'équation de correction des poids (7.5) dans l'approche PHD fait apparaître la vraisemblance $L_Z(\cdot)$ qui doit être calculée pour chaque particule selon les mesures Z du RFS Z_t . Il est impossible de calculer la distance D_{CF} entre un accumulateur particulaire et l'accumulateur complet de la scène perçue. En effet, cette distance est calculée dans le cas mono-objet dans chaque zone d'intérêt représentant un objet. Cet intervalle est déterminé en étudiant la diffusion du nuage particulaire.

Dans le cas d'une approche PHD, le nuage particulaire ne peut être utilisé pour définir un tel intervalle, puisqu'il serait alors une réunion d'ensembles d'indices d'impacts représentant tous les objets présents dans la scène. L'idée est donc de scinder l'accumulateur de la scène Z_t en plusieurs accumulateurs qui constituent alors le RFS des mesures (fig. 7.1). Pour cela, la technique d'indexation des particules employée permet de connaître *a priori* la restriction du nuage particulaire qui approche un objet suivi. À partir de cette restriction, on utilise les outils précédemment développés pour extraire de Z_t l'accumulateur restreint qui représente effectivement l'objet suivi (§6.3.2 et §6.4).

Si on note J_{t-1} le nombre d'objets suivis à l'instant $(t-1)$, il est alors possible de déterminer J_{t-1} accumulateurs représentant chaque zone d'intérêt et que l'on note \tilde{Z}_t^j . Le RFS des observations est alors constitué de l'ensemble de ces accumulateurs, et la phase de pondération peut ensuite se dérouler de la même manière que celle de la pondération effectuée dans l'approche IP-SMC. Connaissant le nuage de particules propre à chaque objet (par l'indexation des particules), les intervalles de pondération pour le calcul de la distance D_{CF} sont déterminés (\mathcal{I}_1 et \mathcal{I}_2) ainsi que les indices d'impact pour la distance $D_\rho(u_1$ et $u_2)$. Contrairement à l'approche IP-SMC, toutes les vraisemblances des particules du nuage approximant la fonction intensité sont alors calculées en utilisant ces paramètres de pondération.




FIGURE 7.1 – Illustration du découpage de l'accumulateur de la mesure pour la constitution du RFS des observations (3 objets)

Cette séparation des accumulateurs est renforcée par le coût calculatoire qu'engendreraient toutes les combinaisons possibles des particules représentant les objets, soit $(\hat{N}_{t-1|t-1}^T)^{J_{t-1}}$ combinaisons possibles.

7.3.2 Exploration de l'espace d'état

L'approche PHD permet une exploration à chaque instant de l'espace d'état par la création de particules exploratrices. Dans la méthode SIP-SMC-PHD, l'exploration de tout l'espace est possible mais nous l'avons conditionné par les mesures (§5.4.2.1). Cette précaution est nécessaire pour ne pas perturber les dynamiques existantes des objets suivis.

Dans la méthode IP-SMC-PHD, il est obligatoire de procéder à un tel conditionnement. En effet, la nature de l'étape de pondération ne permet pas un placement aléatoire des particules dans tout l'espace d'état. La détermination des paramètres de pondération viendrait perturber cette dernière puisque l'ensemble des indices d'impacts peut alors être considéré. Au contraire de la méthode IP-SMC, l'innovation globale est calculée en retirant les accumulateurs représentant les objets suivis, grâce aux états prédits par le filtre, de l'accumulateur complet de l'acquisition. Ceci est indispensable dans le cadre PHD puisque les nouvelles particules doivent être créées avant la phase de mise à jour. Notons $X_{t|t-1}^j$ les J_{t-1} états prédits par l'évolution des particules. Les accumulateurs idéaux $Z_{t|t-1}^j$ sont calculés après reconstruction de la scène télémétrique correspondante. L'innovation est alors donnée par :

$$I_t = Z_t - \sum_{j=1}^{J_{t-1}} Z_{t|t-1}^j \quad (7.6)$$

La fonction I_t représente alors potentiellement les nouveaux objets ou les objets non suivis par le filtre à l'instant précédent. Les mêmes outils d'analyse de l'innovation sont utilisés pour ne pas placer

des particules autour d'objets non représentatifs (section 6.6.1). Si ces conditions sont vérifiées, alors N_t^b/M particules exploratrices sont placées autour des M nouveaux objets, où les composantes vitesses et accélérations sont estimées après une étape d'initialisation basée sur un maillage du sous-espace d'état correspondant (section 6.6.1). À la fin de ce processus, un nuage pondéré de particules décrivant le mouvement de l'objet est construit autour de chaque nouvel état initial \bar{X}_0^j (éq. 5.14) avec une imprécision donnée par Q_0 (éq. 5.15).

7.3.3 « Clutter »

L'un des aspects importants dans l'approche PHD est la prise en compte de clutter qui est intégré dans le RFS des observations. Pour le suivi avec détecteur, le clutter a pu être identifié et intégré comme des fausses alarmes. Pour notre approche IP-SMC-PHD, le clutter peut être assimilé à un accumulateur qui ne représente pas une cible suivie. On peut rappeler que l'une des conditions nécessaires requises pour la construction de l'accumulateur est l'alignement de points. Ainsi, un accumulateur minimal est construit pour au moins 3 impacts laser alignés (triangle de hauteur 1 voisin). Empiriquement, dans le suivi avec détecteur, on peut considérer que 3 données laser par acquisition représentent une borne maximale en tant que points clutter. La densité du clutter suivant par hypothèse une loi de Poisson dans l'approche PHD, on considérera alors finalement que sa probabilité d'apparition est bornée par :

$$p_c \leq \left(\frac{3}{n}\right)^3 \text{ où } n = \text{nombre de points du scan} \quad (7.7)$$

7.4 Gestion de pistes

La notion de trajectoire est indispensable à notre application de suivi mais l'approche PHD ne permet pas, dans son implémentation directe, d'identifier les cibles d'un instant au suivant. On se propose donc pour la méthode IP-SMC-PHD d'utiliser la même approche d'indexation des particules pour estimer la trajectoire de chaque objet (§5.4.2.2).

La notion de création de pistes est un bénéfice apporté par l'exploration de l'espace d'état par N_t^b particules à chaque instant. Cette étape a été décrite dans la section 7.3.2.

Pour construire un système de suivi performant, il reste alors à gérer les cas d'occultation et de disparition d'objets du champ de vision du capteur :

- dans l'approche IP-SMC, une piste possède un indicateur (horizon temporel) qui permet de conserver les particules et les poids après l'étape de prédiction si cet indicateur n'est pas nul. Ce critère entre en jeu quand l'accumulateur restreint à la zone d'étude n'est plus significatif en terme de nombre de voisins (§6.6.2).
- Dans l'approche SIP-SMC-PHD (suivi avec détecteur SIP), une procédure spécifique a été mise en place. Une vérification d'association permet de savoir si un objet suivi n'est pas à proximité d'une mesure. Les particules indexées correspondantes sont alors écartées de l'étape

de mise à jour des poids, si l'horizon temporel associé n'a pas atteint 0. Ces particules et les poids prédits associés sont ensuite réinjectés au niveau de l'étape de séparation des modes afin de procéder à l'estimation des états (5.4.2.3).

Nous avons choisi de combiner ces méthodes précédemment développées afin de construire un processus performant de gestion de disparition de cibles et de défaillances du capteur : chaque groupe de particules (connu grâce à l'indexation) possède un indicateur d'horizon temporel. À l'issue de l'étape de prédiction, la détermination des paramètres de pondération [intervalles \mathcal{I} pour le calcul de la distance entre accumulateurs] permet d'extraire la partie de la fonction cumulative mesurée correspondante à chaque objet. Si celle-ci n'est pas significative, selon les mêmes critères que pour la méthode IP-SMC, alors les particules sont exclues du processus de pondération, dans le cas où l'horizon temporel n'a pas atteint sa valeur minimale. Elles sont ensuite réinjectées dans l'étape de clustering, ce qui permet de ne pas clore une piste existante juste dans un cas de défaillance ponctuelle du capteur, source potentielle de perte de continuité en terme de trajectoire. Dans le cas contraire, elles participent au processus de pondération et sont automatiquement détruites avec la valeur de leur poids.

Finalement, la figure 7.2 illustre une itération de la méthode IP-SMC-PHD développée où les étapes sont synthétisées en différents blocs. On retrouve les blocs :

- « paramètres de pondération » qui regroupe l'ensemble des étapes successives permettant de calculer la distance entre accumulateurs et la distance capteur-objet (fig. 6.8) ;
- « calcul de l'innovation » qui inclut aussi en sortie le test sur le nombre de voisins restant dans l'accumulateur et la taille des segments extraits (fig. 6.8) ;
- « clustering » qui met en œuvre les tests sur la cohérence des groupes extraits (fig. 5.14) ;

7.5 Expérimentations

7.5.1 Données synthétiques

La méthode a d'abord été évaluée et comparée à la méthode PHD qui prend en entrée les détections issues du détecteur SIP (SIP-SMC-PHD) et à la méthode classique de suivi (SM-SMC-JPDA). Dans un second temps, une comparaison entre les deux méthodes sans détecteur est présentée (IP-SMC qui nous sert de référence et IP-SMC-PHD). Le scénario, les données et les bruits associés utilisés restent identiques à ceux utilisés dans l'évaluation de la méthode IP-SMC (§6.8.1.1).

On rappelle également que les critères d'évaluation demeurent les mêmes que les méthodes de suivi avec et sans détection (§5.3.3.1.1 et §6.8.1.1).

Les paramètres communs pour les méthodes sans détection sont ceux utilisés dans la section 6.8.1.

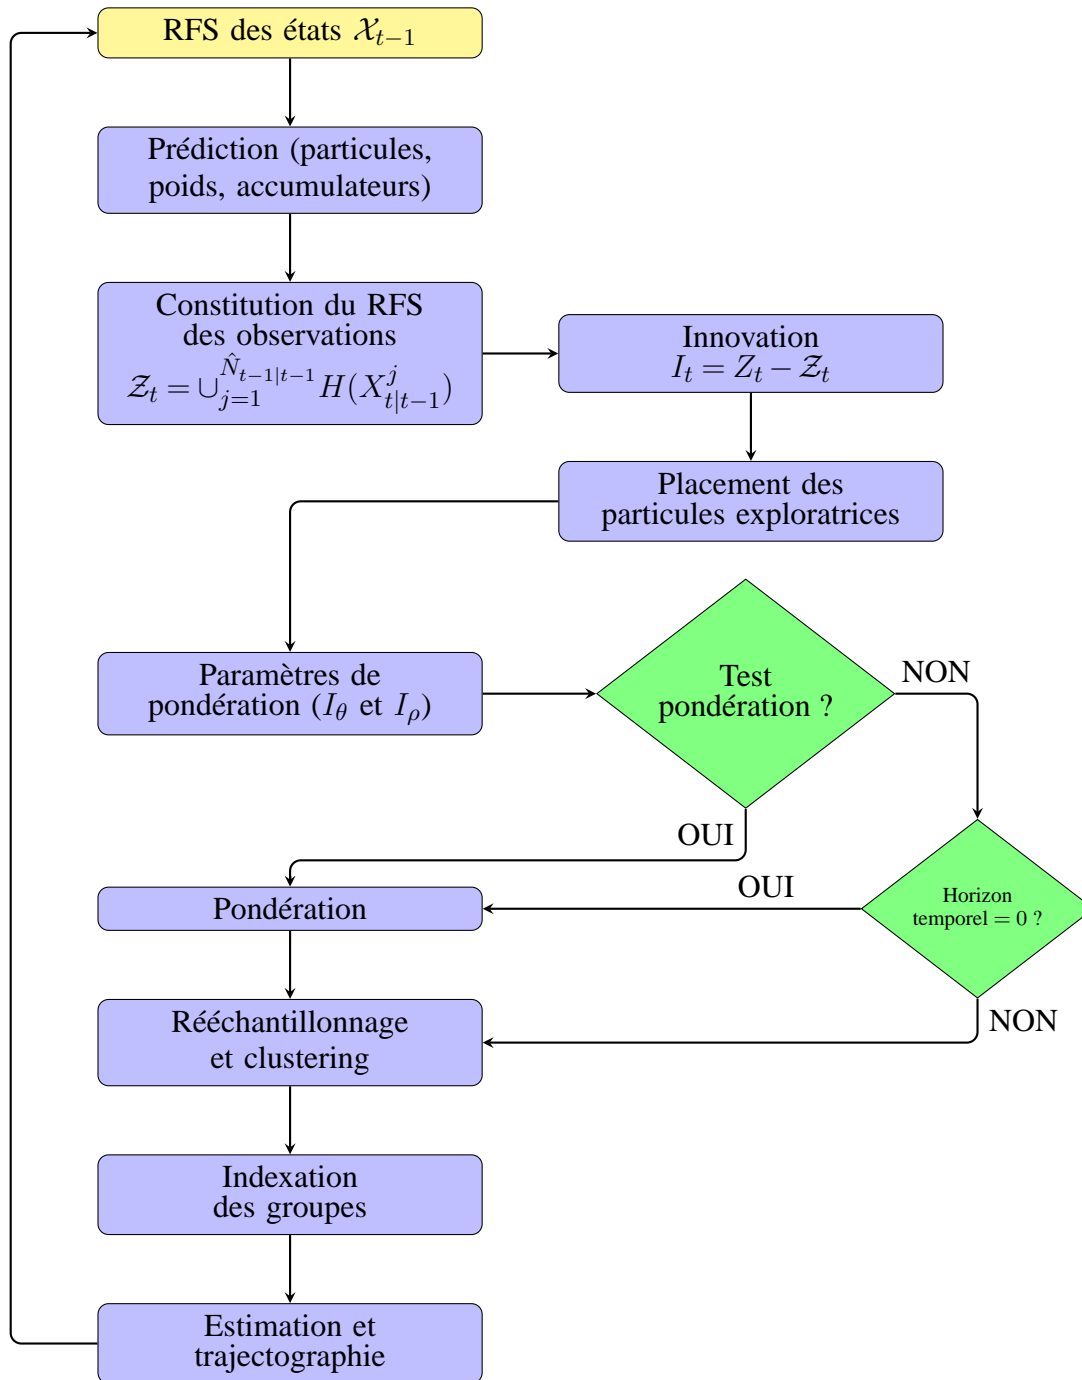


FIGURE 7.2 – Représentation schématique d’une itération de l’algorithme IP-SMC-PHD

7.5.1.1 Résultats

Les normes des estimations sont représentées (fig. 7.3 et 7.4). On peut tirer les mêmes conclusions sur ces données synthétiques que celles obtenues par l'évaluation de la méthode IP-SMC. Le processus de suivi est beaucoup plus stable en travaillant sans détecteur, puisque les non-détections, les fausses alarmes, les mauvaises modélisations issues d'un détecteur ne perturbent pas le processus. La méthode IP-SMC-PHD permet de réduire le nombre de pistes en totalisant 5 pistes créées pour 5 théoriques. L'approche avec détecteur SIP-SMC-PHD est plus perturbée en créant 17 pistes, notamment lors de la présence d'objets aux limites du champ de vision du télémètre. Dans le cadre de notre application, ceci montre également que l'approche PHD permet de bien gérer un cas de suivi multi-cibles. En effet, les figures 7.4 pouvaient laisser envisager un problème dû à l'approche PHD et non à la méthode de suivi avec détecteur. Mais les figures 7.3, qui illustrent la méthode sans détecteur par une approche PHD, montrent les bénéfices apportés conjointement par le cadre PHD et une méthode de suivi sans détecteur.

En terme de précision d'estimation, le tableau 7.1 synthétise les résultats obtenus. La méthode IP-SMC-PHD permet d'améliorer les statistiques d'estimation si on compare avec l'approche SIP-SMC-PHD (facteur 2 sur la précision d'estimation de la position et la vitesse). Les statistiques comparatives avec la méthode SM-SMC-JPDA permettent de confirmer le net bénéfice apporté par un suivi sans détecteur (facteur 15 sur la position par exemple). Le nombre de pistes créées (48) par la méthode JPDA perturbe le processus de suivi et justifie la non-présentation de cette méthode dans la comparaison sur données réelles.

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
Filtre IP-SMC-PHD	0.028	0.065	0.139	1.771	0.046	5
Filtre SIP-SMC-PHD	0.068	0.124	0.130	1.854	0.111	17
Filtre SM-SMC-JPDA	0.436	0.363	0.231	1.908	0.144	48

TABLE 7.1 – Écart-type des erreurs d'estimation pour les différents filtres, distance OSPA-T moyenne et cardinalité pour une précision $\sigma_\rho = 0.03m$

L'estimation de la cardinalité est présentée sur les figures 7.5(b)-(c). L'approche IP-SMC-PHD permet de fournir une bonne estimation lorsque le filtre a convergé, contrairement à la méthode SIP-SMC-PHD qui présente plus d'erreurs. Ceci est confirmé avec la distance OSPA-T (fig. 7.5(a)). D'une part, plus de pics sont présents avec SIP-SMC-PHD indiquant une mauvaise estimation de la cardinalité combinée à une précision d'estimation moindre. D'autre part, en régime nominal des filtres, la méthode proposée est plus précise et confirme les résultats du tableau 7.1 dans lequel la distance OSPA-T a été divisée par 2 comparée à l'approche SIP-SMC-PHD et par 3 pour la méthode classique SM-SMC-JPDA.




FIGURE 7.3 – Estimations de la norme des composantes pour la méthode IP-SMC-PHD : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)




FIGURE 7.4 – Estimations de la norme des composantes pour le SIP-SMC-PHD : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)




FIGURE 7.5 – (a) Distance OSPA-T à chaque itération pour IP-SMC-PHD (noir) et SIP-SMC-PHD (gris) (b) Cardinalité estimée IP-SMC-PHD (trait pointillé) et cardinalité théorique (trait plein) (c) Cardinalité estimée SIP-SMC-PHD

7.5.1.2 Robustesse au bruit

La robustesse de la méthode IP-SMC-PHD est évaluée sur le scénario présenté en 6.8.1.3, dans lequel l'écart-type du bruit de mesure du capteur est fixé à $\sigma_\rho = 0.1\text{m}$.

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s^2)	Orientations (deg)	d_{OSPA}	nombre pistes
Filtre IP-SMC-PHD	0.033	0.099	0.146	0.285	0.044	4
Filtre SIP-SMC-PHD	0.084	0.236	0.288	0.606	0.095	17
Filtre SM-SMC-JPDA	0.609	0.468	0.247	1.499	0.223	64

TABLE 7.2 – Écart-type des erreurs d'estimation pour les différents filtres, distance OSPA-T moyenne et cardinalité pour une précision $\sigma_\rho = 0.1\text{m}$

On retrouve approximativement les mêmes facteurs en terme de gain de précision d'estimation par IP-SMC-PHD comparée aux méthodes avec détection. Toutes les composantes sont mieux esti-

mées par un travail conjoint de détection et de suivi et valide le développement d'une telle méthode dans un cadre de travail PHD.

7.5.1.3 Comparatif des méthodes IP-SMC et IP-SMC-PHD

Finalement, nous procédons à une dernière évaluation sur les données synthétiques qui permet de comparer les deux méthodes de suivi sans détecteur que nous avons développée au cours de la thèse. IP-SMC qui est une approche considérant plusieurs suivis mono-objet, et IP-SMC-PHD qui est la formulation multi-objets de cette même méthode (tableau 7.3). Les deux méthodes se comportent

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)	d_{OSPA}	nombre pistes
Filtre IP-SMC-PHD	0.030	0.065	0.136	1.771	0.046	5
Filtre IP-SMC	0.035	0.071	0.125	1.885	0.050	5

TABLE 7.3 – Écart-type des erreurs d'estimation pour la méthode IP-SMC-PHD et IP-SMC, distance OSPA-T moyenne et cardinalité pour un bruit de mesure d'écart-type $\sigma_\rho = 0.03m$

de manière très similaire dans la continuité du suivi, ce qui explique ces différences mineures, mais présentent finalement deux modélisations possibles du problème de suivi d'objets multiples.

7.5.2 Données réelles

Pour mettre en avant les apports de la dernière méthode PHD, on sélectionne une séquence de 30s (fig. 7.6(a)) dans laquelle la dynamique du véhicule porteur est plus variable (virage en « S » dans lequel le porteur change brusquement de voie). L'orientation des véhicules suivis est donc, en plus, conditionnée par la vitesse angulaire du porteur. Nous effectuons donc une nouvelle étape vers la fusion de capteurs dans le système de perception. La vitesse angulaire est mesurée grâce à une centrale inertielle (fig. 7.6). L'écart-type du bruit de mesure est empiriquement estimé à $\sigma_\omega = 0.25^\circ/s$. L'écart-type du bruit de mesure du capteur télémétrique vaut $\sigma_\rho = 0.05m$. Dans ce scénario, deux véhicules différents évoluent dans la scène, amenant à des situations d'occultation partielle ou totale.

Les paramètres communs aux trois filtres comparés (IP-SMC-PHD, SIP-SMC-PHD et SM-SMC-JPDA) sont ceux des sections 6.8.2, 5.4.4.3 et 5.3.3.2, à l'exception :

- des statistiques du bruit de dynamique sur les accélérations : $\sigma_{\gamma_x}^2 = 1m/s^{-2}$ et $\sigma_{\gamma_y}^2 = 1m/s^{-2}$
 - pour l'initialisation des particules, le maillage est construit avec les bornes suivantes différentes selon les composantes longitudinale ou latérale :
 - $v_{min}^y = 2 v_{min}^x = -2m/s$ et $v_{max}^y = 2 v_{max}^x = +2m/s$
 - $\gamma_{min}^y = 2\gamma_{min}^x = -1m/s^2$ et $\gamma_{max}^y = 2\gamma_{max}^x = +1m/s^2$
- $N_0 = 50000$ particules sont uniformément réparties sur le maillage. L'initialisation a toujours une durée de $n_0 = 20$ itérations.

Les paramètres des filtres PHD comparés sont choisis identiques à ceux utilisés pour les données synthétiques.




FIGURE 7.6 – *Mesure de la vitesse angulaire fournie par la centrale inertielle sur la séquence d'étude.*

7.5.2.1 Résultats

La norme des composantes du vecteur d'état et de l'orientation sont présentées (figs. 7.8 et 7.9). Sur cette séquence réelle différente du chapitre 6, les gains en terme de continuité du suivi apparaissent nettement. Le processus est beaucoup moins perturbé pour la méthode IP-SMC-PHD, ce qui se traduit graphiquement par des courbes en norme d'accélération beaucoup moins perturbées. La représentation de la position permet de constater une amélioration de performance en terme de robustesse, SIP-SMC-PHD étant particulièrement affectée par les nombreuses défaillances du détecteur dans ces données (outliers) même si l'implémentation d'une mémoire pour conserver les pistes existe. L'approche IP-SMC-PHD permet de garantir un temps de suivi beaucoup plus long, diminuant fortement les phases d'initialisation et donc les temps de convergence. Par rapport à la séquence en ligne droite, les objets sont situés plus loin du capteur et sont donc représentés par moins d'impacts. Ainsi, l'accumulateur est beaucoup plus réduit (en terme de nombre de voisins) mais la méthode IP-SMC-PHD fournit tout de même un suivi fiable des cibles, validant notre approche de détection et de suivi conjointe dans des scénarios où la dynamique du véhicule porteur est plus variable.

Méthode	nombre de pistes créées (3 théoriques)
IP-SMC-PHD	4
SIP-SMC-PHD	41
SM-SMC-JPDA	32

TABLE 7.4 – *Nombre total de pistes créées sur une séquence réelle en courbe pour les méthodes IP-SMC-PHD, SIP-SMC-PHD et SM-SMC-JPDA*

Le tableau 7.4 valide les impressions graphiques. L'approche IP-SMC-PHD ne crée que 4 pistes sur un total de 3 théoriques (une seule piste n'étant pas maintenue à l'itération 28). Les méthodes avec détection créent respectivement 41 et 32 pistes pour SIP-SMC-PHD et SM-SMC-JPDA. Enfin, les comparaisons en terme de cardinalité confirment le gain en terme de stabilité apporté par la

méthode IP-SMC-PHD, avec seulement des erreurs d'estimation de cardinalité dues au temps de latence imposée en bord de champ de vision pour débiter un processus de création ou d'arrêt de pistes.

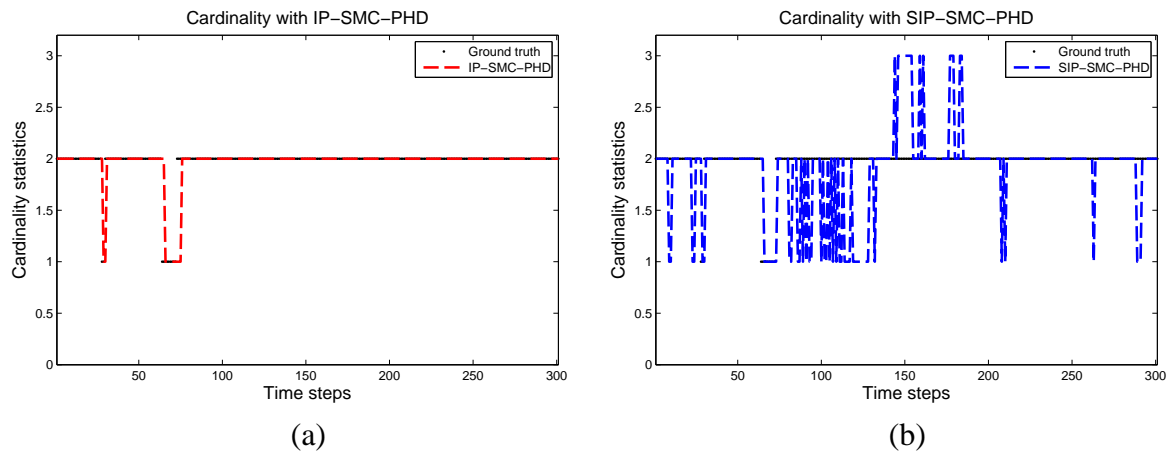


FIGURE 7.7 – (a) Cardinalité estimée (trait pointillé) et cardinalité théorique (trait plein) pour (a) IP-SMC-PHD (b) SIP-SMC-PHD

7.5.2.2 Apport de la centrale inertielle

Les courbes précédentes ont montré l'apport combiné d'un travail directement avec les données télémétriques et des informations fournies par une centrale inertielle pour améliorer le calcul de l'orientation des objets suivis grâce à une connaissance de l'orientation du porteur par un capteur précis. Il peut être intéressant de remarquer l'apport exclusif de la vitesse angulaire sur l'estimation du vecteur d'état (fig. 7.10). Le filtre IP-SMC-PHD a été évaluée sur la même séquence réelle que précédemment, mais en ne prenant pas en compte les mesures de la vitesse angulaire (calcul de l'orientation selon l'éq. 5.11).

Entre les itérations 75 et 84 le véhicule porteur change brusquement de voie. L'objet le plus éloigné, qui était occulté par celui plus proche, entre alors dans le champ de vision du capteur. Le filtre IP-SMC-PHD combiné avec la centrale inertielle permet une initialisation efficace de la piste correspondante qui est alors maintenue jusqu'à la fin de la séquence. Sans la centrale inertielle, on observe un arrêt de la piste lors de ce changement de voie, la piste est alors arrêtée et un nouveau processus d'initialisation démarre pour suivre de nouveau la même cible.

7.6 Conclusion

Ce chapitre a permis de formaliser la méthode de suivi sans détection dans un cadre multi-objets par une approche PHD. En considérant l'accumulateur comme un nouveau processus d'agrégation des données télémétriques, la méthode développée IP-SMC-PHD est une alternative aux méthodes proposées récemment dans la littérature. La méthode est bâtie sur l'approche IP-SMC pour la discrimination des particules entre elles. La phase de pondération spécifique au PHD est développée en




FIGURE 7.8 – Estimations de la norme des composantes pour IP-SMC-PHD en virages avec intégration des données inertielles : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente. Les détectés SIP sont affichés en points verts (à titre indicatif).




FIGURE 7.9 – Estimations de la norme des composantes pour SIP-SMC-PHD en virages avec intégration des données inertielles : (a) positions (b) vitesses (c) accélérations (d) orientation. Chaque nouvelle piste estimée est représentée dans une couleur différente. Les détections SIP sont affichées en points verts.




FIGURE 7.10 – Estimations de la norme de la position pour IP-SMC-PHD en virages (a) avec apport de la centrale inertielle (b) sans apport de la centrale inertielle

construisant le RFS des mesures par séparation des accumulateurs représentant chaque objet suivi. L'exploration de l'espace d'état pour la création des nouvelles pistes a été réalisée en plaçant les particules exploratrices conditionnellement aux mesures. Le calcul de l'innovation globale à chaque itération après la phase de pondération a permis une détectabilité immédiate des nouveaux objets si les critères en terme de nombre minimal de voisins dans l'accumulateur et de taille de segments sont remplis.

L'évaluation faite sur les données synthétiques a une nouvelle fois permis de montrer les différents bénéfices apportés par notre méthode de type « track-before-detect », à savoir plus longue continuité du suivi, robustesse face aux données plus bruitées et aux outliers, nombre de pistes réduit et précision d'estimation largement améliorée. Cependant, le gradient apportée par rapport à la méthode IP-SMC n'est pas important, les résultats étant très similaires. En effet, dans le contexte applicatif, les cibles sont parfaitement résolues (les véhicules sont éloignés les uns des autres). Ainsi, une approche PHD ne permet pas d'apporter tous les aspects qui en font sa force, notamment en terme d'estimation de la cardinalité. Les résultats sont donc équivalents à ceux fournis par une méthode basée sur plusieurs filtres locaux (mono-objet). Dans d'autres contextes avec un nombre très élevé de cibles étendues, le formalisme PHD pourrait sans conteste améliorer les résultats de suivi.

La méthode IP-SMC-PHD a été testée sur des données réelles différentes des chapitres précédents, qui proviennent d'une séquence durant laquelle la dynamique du véhicule porteur subit de plus fortes perturbations (virages plus forts, changements de voie brusques). Une utilisation conjointe de

plusieurs capteurs a donc été mise en place avec l'apport de données de vitesse angulaire fournies par une centrale inertielle. Cet aspect apporte une meilleure estimation de l'orientation des objets suivis, ce qui permet ainsi une reconstruction plus précise de la scène. En termes de résultats sur ces données bruitées, IP-SMC-PHD apporte un suivi robuste et précis en terme de cardinalité, qui n'est pas perturbé par une dynamique plus forte du véhicule porteur. Ces données valident alors définitivement le système de suivi sans détecteur développé au cours de cette thèse.

Chapitre 8

Suivi de cibles distribuées : extension au cas multi-lidar

8.1 Introduction

Les méthodes de suivi de cibles distribuées ont été précédemment développées pour des données fournies par un télémètre placé à l'avant du véhicule porteur. La fusion de sources d'informations hétérogènes (données inertielles, GPS et cartographiques) a permis à la méthode IP-SMC-PHD de suivre des objets lors d'une forte variabilité de la dynamique du véhicule porteur.

L'utilisation conjointe de capteurs différents au sein d'un même système de perception pour l'aide à la conduite est une configuration fréquente [TCD⁺06]. Par exemple, [RFBC12] combine les apports d'un télémètre multicouche et d'un système de stéréo-vision. [KM08, LS11] utilisent par exemple une caméra, un GPS, un odomètre et une centrale inertielle pour procéder au placement du véhicule porteur sur la route empruntée. [HBCB12] propose une méthode de suivi dans laquelle le nombre et la nature ces capteurs utilisés peuvent varier sans changement majeur de la structure de fusion. Un récapitulatif des applications développées dans un contexte multi-capteurs peut être trouvé dans [SLK11, KKKR13].

Dans le cadre de ces travaux, on se propose d'étudier l'apport de plusieurs télémètres dans le système global de perception. Nous avons en effet montré que l'une des limites de notre méthode était le suivi d'objets lorsqu'ils ne sont visibles que partiellement (une seule face visible ou une occultation). Le placement et l'orientation des différents capteurs assure alors une augmentation de la capacité perceptive de l'environnement (fig. 8.1). La généralisation des méthodes de suivi (IP-SMC et IP-SMC-PHD) dans un système composé de plusieurs télémètres peut aussi apporter une redondance d'informations pour les objets qui appartiennent à la zone commune des différents champs de vision. De plus, la fusion de sources d'informations redondantes peut également aboutir à une estimation plus précise et plus fiable des dynamiques des objets suivis.

L'objectif de ce chapitre est de formaliser la méthode de suivi de cibles distribuées présentée dans le chapitre 6 dans un contexte de fusion centralisée de plusieurs capteurs télémétriques, et d'évaluer les résultats de la structure de fusion sur des scènes synthétiques perçues par plusieurs télémètres.




FIGURE 8.1 – Illustration d'une structure multi-capteurs

Ceux-ci sont alors comparés aux résultats d'un suivi obtenu quand l'environnement est perçu par un unique télémètre. Il a été choisi, par compacité et par simplicité calculatoire, de généraliser la méthode IP-SMC dans ce cadre multi-lidar. Cette extension du filtre mono-capteur peut bien sûr être implémentée avec une approche PHD (IP-SMC-PHD).

8.2 Modélisation du mouvement dans une structure de fusion centralisée

8.2.1 Transformations de repères locaux

L'une des problématiques de la fusion de données multi-capteurs est le choix de la structure de fusion. Nous avons choisi d'étudier le problème de suivi d'objets dans le contexte d'une fusion centralisée. Chaque objet sera approché par un nuage particulière dans un repère commun et la phase de pondération interviendra dans chacun des repères locaux des télémètres. Il est ainsi nécessaire de connaître les transformations que subissent les paramètres cinématiques des objets suivis lors du passage d'un repère local à un autre.

La figure 8.2 présente l'architecture spatiale choisie pour traiter le problème. Lors du suivi des cibles mono-capteur, un seul télémètre était placé au centre de l'avant du véhicule (celui-ci étant modélisé comme un rectangle de centre de gravité G), et orienté dans le sens du vecteur vitesse du véhicule porteur \vec{V}_t^{egb} . Nous avons choisi ce repère comme référentiel commun (noté R de centre O). Deux capteurs sont envisagés, mais le problème est bien sûr généralisable à N_c capteurs.

Soit un point M de coordonnées (x^l, y^l) dans un repère local associé à un télémètre (noté R^l de centre O_l). Les télémètres (et donc les repères associés) sont rigidement liés. Il existe ainsi une translation de vecteur \vec{OO}_l (exprimé dans le système de coordonnées du repère R) pour passer du repère local R^l au repère commun R pour trouver les coordonnées (x, y) du point M :




FIGURE 8.2 – Configuration globale du système de perception multi-capteurs

$$\begin{pmatrix} x \\ y \end{pmatrix} = \mathcal{R}_{\theta^l} \left[\begin{pmatrix} x^l \\ y^l \end{pmatrix} + \overrightarrow{OO_l^R} \right] \quad (8.1)$$

\mathcal{R}_{θ^l} est la matrice de rotation d'angle orienté θ^l du repère R^l vers le repère R définie par :

$$\mathcal{R}_{\theta^l} = \begin{pmatrix} \cos \theta^l & \sin \theta^l \\ -\sin \theta^l & \cos \theta^l \end{pmatrix} \quad (8.2)$$

La rigidité des repères associés aux télémètres implique une égalité des vecteurs vitesse et accélération d'après la loi de composition associée (la vitesse angulaire de O_l par rapport à O est nulle et le vecteur vitesse du centre O_l dans le repère R est le vecteur nul).

8.2.2 Calcul de l'orientation dans chaque repère local

Dans le cadre mono-capteur, l'orientation de l'objet suivi se calcule par prise en compte de l'orientation du véhicule porteur (repère monde R^W). Le télémètre est alors orienté dans le sens de déplacement du véhicule porteur, représenté par son vecteur vitesse $\overrightarrow{V^{egb}}$. Dans le cadre d'une structure multi-lidar, il faut prendre en considération les différentes orientations des repères de chaque télémètre pour l'étape de pondération. Le véhicule porteur est représenté par son centre de gravité G dans les lois de composition des vitesses.

Soit M le centre de gravité d'un objet suivi dans un repère local R^l . Le vecteur vitesse de l'objet

\overrightarrow{V}_M exprimé dans le repère monde R^W dépend de la vitesse du centre du repère local O^l :

$$\overrightarrow{V}_M^{R^W} = \overrightarrow{V}_M^{R^l} + \overrightarrow{V}_{O_l}^{R^W} + \overrightarrow{\Omega}_{R^l/R^W} \wedge \overrightarrow{O_l M}^{R^l} \quad (8.3)$$

La vitesse du centre du repère local R^l par rapport au centre du repère R^G étant nulle, la loi de composition des vitesses permet de calculer la vitesse du centre du repère $\overrightarrow{V}_{O_l}^{R^W}$ et on obtient finalement :

$$\overrightarrow{V}_M^{R^W} = \overrightarrow{V}_M^{R^l} + \overrightarrow{V}_G^{R^W} + \overrightarrow{\Omega}_{R^G/R^W} \wedge \overrightarrow{G O_l}^{R^G} + \overrightarrow{\Omega}_{R^l/R^W} \wedge \overrightarrow{O_l M}^{R^l} \quad (8.4)$$

Dans l'équation 8.4, la vitesse du véhicule porteur dans le repère monde $\overrightarrow{V}_G^{R^W}$ est exprimée dans le système de coordonnées R^l et doit alors prendre en considération l'orientation du capteur par rapport au sens de déplacement du véhicule porteur (modélisé par l'angle orienté θ_l). Finalement, sous l'hypothèse de repères R^l et R^G rigidement liés, l'orientation ψ_M de l'objet M dans le repère monde se calcule par :

$$\psi_M = \arctan \frac{v^y + \omega (x + x_{O_l}^{R^G}) + \|\overrightarrow{V}^{egb}\| \cos \theta_l}{v^x - \omega (y + y_{O_l}^{R^G}) + \|\overrightarrow{V}^{egb}\| \sin \theta_l} \quad (8.5)$$

où

- x, y, v^x, v^y sont les paramètres cinématiques de l'objet dans le repère local considéré ;
- $x_{O_l}^{R^G}, y_{O_l}^{R^G}$ sont les coordonnées du capteur dans le repère du centre de gravité de l'objet ;
- θ_l est l'orientation du capteur télémétrique par rapport au référentiel R ;
- ω est la vitesse angulaire du véhicule porteur.

Cette orientation est utilisée pour placer les objets dans la scène reconstituée et ainsi calculer les accumulateurs particulières correspondants dans chaque repère local associé aux télémètres.

8.3 Modélisation globale du problème dans un contexte multi-capteurs

On propose d'étendre la formulation de l'approche IP-SMC (chap. 6) à un contexte multi-capteurs.

D'un point de vue général, on dispose d'un ensemble de N_c capteurs qui délivrent chacun une acquisition de la scène courante. On peut alors modéliser le problème par le système suivant :

$$\begin{cases} X_t & = f(X_{t-1}, W_t) = F X_{t-1} + W_t \\ Z_t^1 & = H_1(X_t) + \nu_t^1 \\ \vdots & \vdots \\ Z_t^{N_c} & = H_{N_c}(X_t) + \nu_t^{N_c} \end{cases} \quad (8.6)$$

où

X_t est le vecteur d'état décrivant les paramètres cinématiques de l'objet ;

F est la fonction de dynamique caractérisant le flot du système ;

H_l sont les fonctions d'observation non linéaires ;

W_t est un bruit blanc de dynamique, gaussien, de moyenne nulle et de loi connue ;

$\{Z_t^l\}_{l=1}^{N_c}$ est l'ensemble des impacts des N_c mesures issues des capteurs ;

$\{\nu_t^l\}_{l=1}^{N_c}$ sont les bruits blancs gaussiens additifs de moyennes nulles et de covariances Σ^l .

Les N_c acquisitions télémétriques forment la base du problème de fusion centralisée. Les propriétés d'invariance géométrique fondatrices de la méthode de suivi sans détection IP-SMC possèdent un unique paramètre de résolution angulaire α^l du capteur. On pourrait envisager de construire un système dans lequel les capteurs télémétriques n'ont pas la même résolution angulaire, et donc un nombre différent d'impacts lors de l'acquisition. Dans le formalisme de la méthode multi-capteurs développée, on suppose que les N_c acquisitions sont synchronisées. Les déformations liées à la différence entre les débuts et fins d'acquisition sont assimilées aux bruits de mesure.

8.4 Structure générale de la méthode particulière de suivi multi-lidar

La structure retenue de fusion centralisée permet de prendre en compte les mesures dans le processus de suivi sans qu'elles soient transformées. La structure générale du filtre est décrite ci-après.

En notant $X_t^j = (x_t^j, v_t^{x,j}, \gamma_t^{x,j}, y_t^j, v_t^{y,j}, \gamma_t^{y,j})^T$ le vecteur d'état qui caractérise l'objet indicé j à l'instant t , une approximation particulière de cet état est obtenue à chaque instant (éq. 5.12). L'espace d'état choisi ici est le même que dans le cas mono-capteur (l'origine étant située au centre du pare-choc avant du véhicule de coordonnées $(0, L/2)$ dans le repère R^G pour nos données synthétiques par exemple). L'objectif est d'obtenir à chaque instant les poids et positions de chaque particule pour chaque objet selon l'enchaînement des étapes classiques d'un filtre particulier IP-SMC en prenant en compte l'ensemble des N_c acquisitions issues des capteurs.

1. Initialisation : un nuage pondéré de particules décrivant le mouvement de l'objet est construit autour de chaque état initial \bar{X}_0^j (éq. 5.14). La détermination des paramètres initiaux de l'état est une procédure analogue à celle développée pour les méthodes de suivi sans détecteur (IP-SMC et IP-SMC-PHD). L'utilisation de plusieurs capteurs implique une modification de cette étape d'initialisation afin de ne pas induire une multiple initialisation du même objet. Cette procédure sera décrite en 8.5.

2. Prédiction : L'étape de prédiction des états des objets et de leur poids est identique à celle effectuée dans les méthode de suivi mono-capteur (§6.5.2). Pour chaque piste j représentée par

son nuage à l'instant $(t - 1)$, les particules évoluent indépendamment dans l'espace d'état selon la distribution d'importance $q_t(X_t^j | X_{t-1}^{j,(i)}, Z_t)$. Les poids prédits sont alors donnés par :

$$\forall j \in [1, J_t], \forall i \in [1, N_p], \omega_{t|t-1}^{j,(i)} = \frac{p(X_t^j | X_{t-1}^{j,(i)})}{q_t(X_t^j | X_{t-1}^{j,(i)}, Z_t)} \omega_{t-1}^{j,(i)} \quad (8.7)$$

L'état prédit de chaque objet est obtenu par somme pondérée des états prédits des particules (éq. 6.17). Il permet de déterminer les indices d'impacts pour le calcul de la distance entre le capteur et l'objet.

3. Mise à jour : il s'agit de l'étape clé dans la structure de fusion choisie. Nous la décrivons pour un objet j suivi à l'instant $(t - 1)$ (l'indice j est volontairement omis dans la suite). Cette étape est répétée autant de fois qu'il y a d'objets dans la scène (filtres locaux indépendants). À la différence du cas mono-capteur où les scènes étaient reconstruites directement dans l'espace d'observation associé au repère télémétrique, un passage entre l'espace d'état courant et les N_c espaces d'observation est nécessaire. Celui-ci s'effectue en appliquant la transformation inverse de l'équation 8.1 pour la composante en position. La rigidité des repères locaux entre eux entraîne alors une rotation des composantes vitesses et accélérations :

$$\left\{ \begin{array}{l} \begin{pmatrix} v_t^{x,l} \\ v_t^{y,l} \end{pmatrix} = \mathcal{R}_{\theta^l}^{-1} \begin{pmatrix} v_t^x \\ v_t^y \end{pmatrix} \\ \begin{pmatrix} \gamma_t^{x,l} \\ \gamma_t^{y,l} \end{pmatrix} = \mathcal{R}_{\theta^l}^{-1} \begin{pmatrix} \gamma_t^x \\ \gamma_t^y \end{pmatrix} \end{array} \right. \quad (8.8)$$

où $v_t^{x,l}, v_t^{y,l}, \gamma_t^{x,l}, \gamma_t^{y,l}$ représentent les composantes vitesses et accélérations dans chaque repère local du capteur indicé l et $v_t^x, v_t^y, \gamma_t^x, \gamma_t^y$ sont les composantes vitesses et accélérations du vecteur d'état (exprimées dans le repère R choisi pour la structure de fusion).

L'approximation particulière de la vraisemblance locale dans chacun des repères associés aux télémètres est calculée suivant le même cheminement d'étapes décrites en 6.5.2, à savoir :

- sélection de la zone d'intérêt dans l'accumulateur de la mesure correspondant à l'objet suivi ;
- calcul de la distance entre l'accumulateur de la mesure et l'accumulateur particulière (reconstruit dans le repère local correspondant) ;
- calcul de la distance entre le capteur local considéré et la particule.

Il est alors possible, pour chaque particule, de calculer la vraisemblance sachant les impacts télémétriques fournis par chaque capteur l . Celle-ci est obtenue à partir de la log-vraisemblance $L_{Z_t^l}^{(i)}$ donnée par l'équation 6.21 :

$$\forall i \in [1, N_p], p(Z_t^l | X_{t|t-1}^{(i)}) = \exp \left(L_{Z_t^l}^{(i)} \right) \quad (8.9)$$

Finalement, la vraisemblance de la particule i sachant toutes les mesures s'obtient par le produit des vraisemblances locales :

$$\forall i \in \llbracket 1, N_p \rrbracket, p(Z_t | X_{t|t-1}^{(i)}) = \prod_{l=1}^{N_c} p(Z_t^l | X_{t|t-1}^{(i)}) \quad (8.10)$$

La mise à jour des poids s'effectue alors de manière classique :

$$\forall i \in \llbracket 1, N_p \rrbracket, \omega_{t|t}^{(i)} = \frac{p(Z_t | X_{t|t-1}^{(i)})}{\sum_{k=1}^{N_p} \omega_{t|t-1}^{(k)} p(Z_t | X_{t|t-1}^{(k)})} \omega_{t|t-1}^{(i)} \quad (8.11)$$

La figure 8.3 présente la procédure permettant le calcul des poids pour un objet suivi à l'instant $(t - 1)$. Celle-ci est répétée pour chacun des J_{t-1} objets présents dans la scène.

4. Rééchantillonnage : une phase de rééchantillonnage basée sur la procédure de redistribution multinomiale est identiquement appliquée comme dans le paragraphe 6.5.2.

8.5 Gestion de pistes

8.5.1 Gestion de l'occultation et arrêt de pistes

La méthode IP-SMC développée précédemment dans le cas mono-capteur a été complétée par une procédure de destruction de pistes. La notion d'horizon temporel que nous avons développée permet de palier les cas de non-pondération qui surviennent quand :

- la restriction de l'accumulateur de la mesure représentant l'objet suivi présente un nombre insuffisant d'impacts appartenant à un même segment ;
- la distance entre les impacts utilisés pour le calcul de la distance capteur-objet est supérieure à un seuil (conditionné par une connaissance *a priori* des dimensions des objets suivis).

La vérification de ces deux conditions implique une non-pondération de l'état de l'objet, celui-ci passant alors pendant un temps (lié à l'horizon temporel) en prédiction pure avant de stopper la piste s'il ne réapparaît plus dans la scène.

On propose alors d'étendre la même technique au cas multi-capteurs. L'objectif est alors de limiter ces cas de non-pondération. En effet, une piste passera en prédiction pure à la seule condition que le calcul des poids des particules est impossible (objet non perçu par les N_c capteurs simultanément). L'avantage apparaît nettement en cas de défaillance d'un des télémètres. De plus, les objets qui disparaissent du champ de vision d'un télémètre peuvent toujours être perçus par d'autres, augmentant ainsi son temps de suivi. Si aucun des télémètres ne perçoit l'objet, alors le processus de destruction de pistes est mis en œuvre comme décrit dans le paragraphe 6.6.2 si l'horizon temporel est nul.

8.5.2 Création de pistes

Tout comme la méthode IP-SMC développée dans le cas mono-capteur, une procédure spécifique de création de pistes a été développée afin de gérer l'apparition de nouveaux objets dans le champ de




FIGURE 8.3 – Architecture de la structure de fusion multi-lidar pour l'estimation du vecteur d'état d'un objet suivi à l'instant $(t - 1)$

vision d'un ou de plusieurs télémètres. Celle-ci est basée sur le calcul de l'innovation dans chaque repère local R^l :

$$I_t^l = Z_t^l - \sum_{j=1}^{J_t} \tilde{Z}_t^{l,j} \tag{8.12}$$

où J_t est le nombre d'objets suivis, l est l'indice du capteur et $\tilde{Z}_t^{l,j}$ sont les accumulateurs restreints à chaque objet et utilisés pour la pondération des particules. Ceux-ci sont différents dans chaque repère local. Si l'accumulateur I_t^l est suffisamment significatif d'un objet (critère de nombre d'im-

pacts combiné avec une taille de segment minimale), alors une procédure d'initialisation démarre dans le repère local R^l . Celle-ci se base sur un maillage de l'espace d'état local pour calculer les composantes initiales du vecteur d'état (§5.3.2.1). Ces composantes sont alors uniquement connues dans le repère R^l et les transformations (8.1) et (8.8) sont appliquées pour la diffusion du nuage particulaire de ce nouvel objet dans l'espace d'état centralisé (*i.e.* le repère R). À la sortie de ce processus, l'accumulateur théorique du nouvel objet dans chaque repère local est calculé et soustrait de I_t^l afin de ne pas initialiser plusieurs fois un objet perçu par plusieurs capteurs.

8.6 Résultats expérimentaux

La méthode de suivi développée dans un contexte de fusion multi-capteurs a uniquement pu être évaluée sur des données synthétiques (absence de données réelles pour ce type d'acquisitions).

8.6.1 Système de perception multi-lidar

Le cadre théorique précédemment détaillé a été appliqué au cas particulier d'un système de perception composé de deux télémètres laser. Le simulateur a été modifié pour permettre de placer des capteurs additionnels sur le véhicule porteur. Un télémètre à l'avant-gauche (coordonnées $(-larg_veh/2, long_veh/2)$ dans le repère R^G) et un autre à l'avant-droit (coordonnées $(larg_veh/2, long_veh/2)$) ont ainsi été ajoutés.

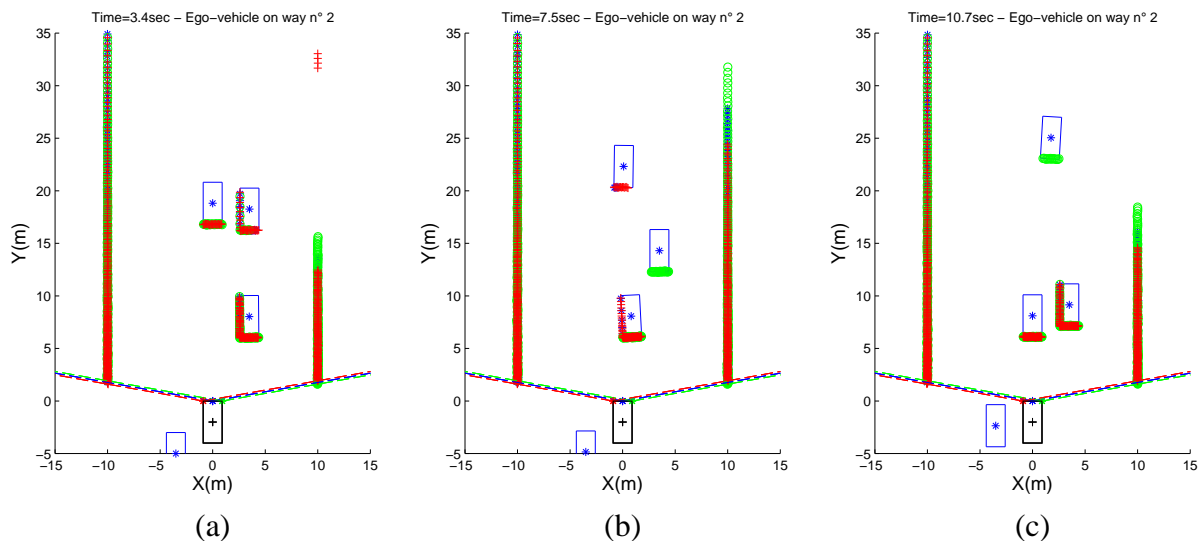


FIGURE 8.4 – Exemples d'acquisitions fournies conjointement par un capteur central (croix bleues), droit (cercles verts) et gauche (plus rouges) : (a) configuration idéale de perception totale par tous les capteurs (b) occultations de deux objets (c) occultation de l'objet le plus éloigné.

Ce placement des capteurs aux extrémités du véhicule porteur permet d'obtenir des situations particulières qui peuvent aboutir à une meilleure qualité de suivi que dans le cas mono-capteur si la structure de fusion est correctement mise en place (fig. 8.4). Les cas d'occultations (partielles ou complètes) peuvent être atténués par l'apport de ces autres capteurs. En effet, sur la fig. 8.4(b), le

véhicule le plus éloigné est uniquement visible par le capteur gauche, et l'objet à droite est uniquement visible par le capteur droit. Le capteur central ne perçoit que l'objet le plus proche. La figure 8.4(c) illustre un cas d'occultation totale par deux capteurs (télémètres central et gauche) : l'objet le plus éloigné est uniquement visible par le capteur droit. Un objet est donc visible plus longtemps en considérant l'ensemble du système de perception télémétrique. Nous allons montrer que le suivi est maintenu plus longtemps, ce qui semble pertinent pour la qualité globale du système.

8.6.2 Configuration routière étudiée et protocole d'évaluation

Le scénario simulé pour l'évaluation consiste à suivre 4 objets pendant 35s. Ils évoluent dans un environnement composé de 3 voies de circulation dans lequel le véhicule porteur des télémètres est positionné sur la voie centrale et roule à une vitesse de 50km/h. Toutes les configurations de circulation apparaissent (occultation, apparition et disparition des champs de vision des télémètres). L'écart-type du bruit de mesure des capteurs télémétriques est identique pour chaque capteur et fixé à $\sigma_\rho = 0.03\text{m}$ et la période d'acquisition est la même pour chacun des télémètres ($\Delta t = 0.1\text{s}$).

Le protocole d'évaluation mis en place pour l'évaluation de la structure de fusion centralisée est différent de ceux développés dans les méthodes de suivi mono-lidar. En effet, la différence de visibilité des différents objets empêche d'étudier les notions de cardinalité (un objet visible par le capteur droit ne l'est pas forcément par le capteur gauche). La distance OSPA-T, basée sur la cardinalité d'un ensemble théorique d'objets dans la scène à chaque instant, n'a donc plus de sens et n'est pas calculée.

Les objets de la scène sont suivis à l'aide de la méthode IP-SMC multi-capteurs développée et les résultats sont comparés à un suivi IP-SMC avec un unique télémètre (droit ou gauche). Les critères d'évaluation que nous avons alors retenus sont :

- la **précision d'estimation** qui est calculée sur les instants communs de suivi par les différentes méthodes (pas de biais introduit par la non-visibilité des objets par certains capteurs) ;
- le **temps de suivi** pour chaque objet présent dans la scène. Il s'agit alors de calculer le temps total pendant lequel l'approche étudiée suit l'objet. Ce temps est indicatif et ne peut pas être comparé à un temps « théorique » de présence.

Les différents paramètres nécessaires aux algorithmes sont communs à chaque méthode de suivi et sont identiques à ceux de la section 6.8.1, sauf :

- les statistiques du bruit de dynamique sur les accélérations : $\sigma_{\gamma_x}^2 = 0.40\text{m/s}^{-2}$ et $\sigma_{\gamma_y}^2 = 0.40\text{m/s}^{-2}$

8.6.3 Résultats

Les figures 8.5 présentent uniquement la norme des positions estimées par chaque méthode. La continuité des pistes est mieux assurée dans une structure de fusion. Entre l'itération 220 et 240, un objet en occulte un autre et la méthode IP-SMC multi-lidar permet d'assurer la continuité du suivi de cette piste à ces instants. Avec l'utilisation d'un seul capteur (figures 8.5(b)-(c)), le suivi de cet objet particulier est interrompu, et une nouvelle procédure d'initialisation doit ainsi démarrer quand




FIGURE 8.5 – Estimations de la norme des composantes pour le (a) IP-SMC multi-capteurs (b) IP-SMC avec données issues du capteur droit (c) IP-SMC avec données issues du capteur gauche. Chaque nouvelle piste estimée est représentée dans une couleur différente et comparée aux pistes références (tirets noirs)

il réapparaît. La structure de fusion est ainsi capable de réduire ces phases d'initialisation en tirant avantage des différents champs de vision.

Un deuxième bénéfice important est le temps de suivi d'un objet. Prenons l'exemple de l'objet le plus éloigné à partir de l'itération 105. Pour le capteur droit, cet objet est visible et la méthode IP-SMC mono-capteur suit l'objet (fig. 8.5(b)). Par contre, cet objet ne devient visible par l'autre capteur que bien plus tard dans la séquence (itération 202 pour le capteur gauche). Le filtre IP-SMC multi-lidar est alors capable de suivre l'objet grâce au capteur droit. La même remarque est faite pour l'itération 60 ou pour l'itération 210 où le suivi d'un objet n'est pas du tout interrompu lors d'une occultation. Dans des situations d'occultation partielle ou totale par un capteur, la structure de fusion développée permet d'optimiser le suivi en tenant compte des mesures disponibles par d'autres capteurs.

Ce gain en terme de temps de suivi est confirmé par le tableau 8.1. Pour chaque piste, on détermine de manière absolue le temps pendant lequel l'objet correspondant est suivi par chacun des filtres. Dans une configuration idéale où chaque objet est visible par les deux capteurs, le temps de suivi est le même (piste n°1). Les autres pistes (notamment la piste n°4), sont suivis plus longtemps avec l'approche IP-SMC multi-capteurs. Cette plus longue période de suivi permet alors de conserver un nuage particulaire approximant de la meilleure des manières l'objet à suivre puisqu'une pondération peut toujours avoir lieu dès que le nombre d'impacts d'un des capteurs est suffisant. Le filtre avec la fusion permet de suivre un objet plus longtemps qu'avec le temps maximum de suivi par l'un des deux capteurs. De plus, les phases d'initialisation peuvent aussi être réduites.

Piste n°	1	2	3	4
Filtre IP-SMC multi-lidar	35	14.3	22.7	30.1
Filtre IP-SMC capteur droit	35	13.3	21.7	28.8
Filtre IP-SMC capteur gauche	35	13.1	21.6	19.7

TABLE 8.1 – Temps de suivi (en secondes) de chaque piste pour le scénario avec un bruit de mesure d'écart-type $\sigma_\rho = 0.03m$

Écart-type	Position (m)	Vitesse (m/s)	Accélération (m/s ²)	Orientation (deg)
Filtre IP-SMC multi-lidar	0.016	0.046	0.091	0.966
Filtre IP-SMC capteur droit	0.064	0.082	0.135	1.116
Filtre IP-SMC capteur gauche	0.032	0.067	0.114	1.010

TABLE 8.2 – Écart-type des erreurs d'estimation pour la méthode IP-SMC multi-capteurs et IP-SMC pour chaque capteur pour le scénario avec un bruit de mesure d'écart-type $\sigma_\rho = 0.03m$

Ceci joue alors un rôle sur la précision d'estimation (tableau 8.2). Le filtre IP-SMC multi-capteurs multiplie par deux la précision d'estimation de la position si on compare avec le meilleur résultat fournie par une méthode IP-SMC mono-capteur (le capteur gauche dans ce cas). Les précisions en vitesse, accélération et orientation sont aussi également meilleures qu'avec n'importe quelle méthode de suivi mono-capteur.

8.7 Conclusion

Ce dernier chapitre a présenté une première approche d'extension de la méthode conjointe de détection et de suivi de cibles distribuées IP-SMC au cas multi-lidar. L'utilisation d'un système de perception multi-lidar dans une structure de fusion centralisée permet une couverture plus large de la région d'observation. Les cas d'occultation peuvent notamment être réduits, et le suivi des objets est assuré pendant un temps plus long que le temps maximal de suivi lorsque le système de perception se limite à un seul capteur. Un placement judicieux de plusieurs capteurs télémétriques peut ainsi amener à une surveillance continue de la zone d'intérêt autour du véhicule porteur. Cette structure de fusion permet également un gain significatif en terme de précision d'estimation, en augmentant celle-ci significativement comparé aux meilleurs résultats fournis par une méthode de suivi dans un système composé d'un seul télémètre.

Conclusion générale et perspectives

Dans le cadre de notre contribution au suivi multi-objets à partir de mesures distribuées, nous avons développé et validé différentes méthodes globales. Celles-ci ont été appliquées à un système de perception multi-capteurs centré autour d'un télémètre à balayage embarqué sur un véhicule. Le cadre général de ce travail concerne les systèmes d'aide à la conduite.

Le développement et l'amélioration d'une nouvelle méthode de détection dans les données télé-métriques a été le point de départ de cette thèse. En effet, il s'agissait de lever certaines contraintes des méthodes classiques de segmentation, à savoir un passage en coordonnées cartésiennes ne préservant pas les statistiques du bruit de mesure, mais aussi l'utilisation des distances inter-impacts. Cette détection, bâtie autour des propriétés d'invariance géométrique, a été implémentée et comparée aux autres approches couramment rencontrées dans ce type d'application. Elle a montré des résultats significatifs par une augmentation de la précision et une diminution de l'incertitude par une minimisation du taux de fausse alarme [FLN12a, NLF10].

L'étape suivante était le suivi multi-objets par des filtres d'estimation alimentés par les données de ce détecteur. Une étape de modélisation sous forme de rectangle était alors nécessaire pour convertir les segments en observations (positions et orientation) compatible avec le modèle dynamique envisagé. Les non-linéarités du modèle d'observation ont été traitées par les méthodes de Monte Carlo séquentielles. Le filtre JPDA couramment utilisé a été alors mis en œuvre sous une formulation particulière et des mécanismes de gestion de pistes (apparition, maintien, disparition) propres aux méthodes de suivi avec association ont été élaborés. Cependant, le filtre JPDA reste fortement conditionné d'une part par une hypothèse d'un nombre connu de cibles à chaque instant, et d'autre part par la phase d'association elle-même. Pour palier ces contraintes, nous avons mis en place une approche basée sur le filtrage PHD, nécessitant une attention particulière lors de l'initialisation des pistes. Les particules exploratrices sont alors diffusées après avoir évoluées sur une grille échantillonnant un sous-espace de l'espace d'état. Ces méthodes ont été validées et mises en concurrence sans toutefois montrer une hiérarchie bien établie. Cependant, nous avons pu une nouvelle fois montrer l'intérêt de notre détecteur [FLN13c].

Même si le détecteur présente peu de problème de fausse alarme ou de non détection, les méthodes de suivi restent dépendantes des éventuelles défaillances de celui-ci. Nous avons alors proposé une nouvelle approche de type *track-before-detect* pour laquelle la détection est réalisée de manière conjointe au processus de suivi. Pour cela, nous nous sommes appuyés sur les bases du

détecteur SIP proposé dans ce manuscrit, qui exploite les propriétés d'invariance géométrique en procédant à une transformation de l'espace des mesures. Nous avons ainsi construit une méthode de suivi qui, contrairement au cas du suivi réalisé en sortie de détecteur (basé sur les positions et orientation estimées des objets), exploite directement les mesures brutes, c'est-à-dire l'ensemble des impacts appartenant à chaque objet. L'utilisation de cette représentation a conduit au développement de nouvelles politiques de pondération et de gestion de pistes, au travers d'une étape d'association entre le modèle de l'objet et les mesures transformées. Cette phase d'association repose sur un filtre adapté à chaque objet suivi et permet de traiter conjointement le problème de détection et suivi multi-cibles.

De manière alternative, nous avons également exploité le formalisme PHD afin de traiter conjointement l'ensemble des cibles à chaque instant. Les approches développées ont été, là aussi, validées sur données synthétiques et réelles, et la comparaison avec les autres méthodes de suivi de ce mémoire a montré des gains significatifs en termes de précision, fausses alarmes et maintien de pistes. Étant donné le nombre restreint d'objets à suivre, il a été difficile de montrer un apport en termes de précision pour les méthodes PHD dont l'efficacité relative augmente avec le nombre d'objets à suivre. Cependant, ces méthodes conservent l'avantage de gérer automatiquement la gestion de pistes [FLN13b, FLN12b, FLN13a].

Les méthodes précédentes ont nécessité un apport d'informations supplémentaires liées au contexte de l'étude, par exemple pour la limitation de la zone d'observation et la détermination de la dynamique du véhicule porteur. La dernière partie de cette thèse se propose de généraliser le cadre d'étude à un système multi-capteurs basé sur plusieurs télémètres embarqués sur le véhicule et de montrer l'apport d'une structure de fusion centralisée pour des données complémentaires et redondantes. La comparaison des résultats de cette nouvelle approche avec une méthode de suivi mono-lidar a montré l'intérêt d'une telle structure de fusion, en particulier pour certaines configurations critiques : gestion des occultations par exemple.

Les travaux réalisés dans ce mémoire ouvrent de nombreuses perspectives :

- les approches basées-modèles développées dans ce mémoire ont été formalisées et validées en conservant l'hypothèse d'un suivi d'objets de tailles similaires. Bien que la robustesse de cette méthode ait été démontrée pour une légère variabilité de la taille des véhicules en données réelles, la levée de cette hypothèse par une intégration des dimensions du modèle dans le processus global de suivi peut augmenter la précision notamment en situations réelles de circulation. La prise en compte de ce paramètre peut se faire soit directement dans le processus d'estimation du vecteur d'état, soit par une phase d'identification préalable au processus de suivi.
- le cadre applicatif de cette thèse a été le suivi de véhicules, avec le choix d'un modèle rectangulaire. Toutes les méthodes de suivi développées peuvent être généralisées à un suivi d'objets polyédriques quelconques. Pour les approches utilisant un détecteur, seule la phase de modélisation diffère après l'étape de segmentation. Pour les approches *track-before-detect*, la mise en

- forme des données (accumulateur) sera différente et nécessitera des ajustements uniquement dans la phase de pondération.
- toutes les méthodes de suivi validées utilisent un modèle cinématique simple mais suffisant pour le suivi de véhicules. On peut envisager d'exploiter une gamme plus large de modèles dynamiques. Cette perspective peut aussi être couplée à une approche multi-modèles plus générale (en terme de modèles géométriques).
 - au niveau d'un système multi-téléètres : la méthode de suivi dans une structure multi-lidar a seulement pu être évaluée sur données synthétiques, et une étape supplémentaire serait de la valider définitivement sur des données réelles. La fusion centralisée a été développée, et une comparaison avec une fusion décentralisée pourrait être réalisée.
 - différentes sources d'informations ont été utilisées directement dans le processus d'estimation, notamment pour apporter une connaissance contextuelle plus précise de la localisation et la dynamique du véhicule porteur. On peut aussi envisager une utilisation conjointe d'autres capteurs extéroceptifs dans le système de perception (caméra). Ceux-ci permettront d'une part une amélioration des performances de suivi et d'autre part une aide au processus d'identification des objets par exemple.
 - on peut enfin imaginer une utilisation de ces méthodes dans d'autres applications, soit toujours lorsque le capteur est embarqué sur un objet en mouvement, soit dans une surveillance de zone dans lesquelles le télétertre pourrait simplement être fixe, sans aucune connaissance nécessaire autre que sa localisation (zone de circulation à risque comme les parkings pour le suivi de véhicules, les ports pour le suivi de bateaux, ...).

Annexe A

Calcul des deux premiers moments de l'invariant géométrique A_k

Considérons la fonction cumulative A_k , définie pour un point central $P_i (\rho_i, \theta_i)$:

$$A_k(i) = \frac{\sum_{j=i-k}^{j=i+k} \frac{1}{\rho_j}}{\frac{1}{\rho_i}} \quad (\text{A.1})$$

$A_k(i)$ est une variable aléatoire et on cherche alors à calculer ses deux premiers moments (moyenne et variance). On utilise alors les équations 3.3 et 3.5. Pour ne pas alourdir l'écriture, ce calcul est effectué pour 3 points consécutifs, c'est-à-dire un voisinage de 1 autour du points central P_i et une généralisation pour un voisinage k sera faite. Nous avons donc :

$$A_1(i) = \frac{\frac{1}{\rho_{i-1} + \nu_{i-1}} + \frac{1}{\rho_i + \nu_i} + \frac{1}{\rho_{i+1} + \nu_{i+1}}}{\frac{1}{\rho_i + \nu_i}}$$

soit encore

$$A_1(i) = 1 + \frac{\rho_i + \nu_i}{\rho_{i-1}} \times \frac{1}{1 + \frac{\nu_{i-1}}{\rho_{i-1}}} + \frac{\rho_i + \nu_i}{\rho_{i+1}} \times \frac{1}{1 + \frac{\nu_{i+1}}{\rho_{i+1}}}$$

Un développement limité de $\frac{1}{1+x}$ d'ordre 1 peut alors être appliqué. Cette approximation est possible quand $|x| \ll 1$. Cette hypothèse est naturelle dans le cadre de ces travaux. En effet, pour des capteurs télémétriques, la mesure de distance minimale est de l'ordre de 2m. Un bruit de mesure important tel que $\sigma_\rho = 0.1\text{m}$ amène à $\frac{\nu_i}{\rho_i} \approx 0.05$. La condition est donc remplie. On obtient alors une approximation de $A_1(i)$:

$$A_1(i) \approx 1 + \frac{\rho_i + \nu_i}{\rho_{i-1}} \times \left(1 - \frac{\nu_{i-1}}{\rho_{i-1}}\right) + \frac{\rho_i + \nu_i}{\rho_{i+1}} \times \left(1 - \frac{\nu_{i+1}}{\rho_{i+1}}\right)$$

$$A_1(i) \approx 1 + \frac{\rho_i}{\rho_{i-1}} + \frac{\rho_i}{\rho_{i+1}} - \frac{\rho_i \nu_{i-1}}{(\rho_{i-1})^2} - \frac{\rho_i \nu_{i+1}}{(\rho_{i+1})^2} + \frac{\nu_i}{\rho_{i-1}} + \frac{\nu_i}{\rho_{i+1}} - \frac{\nu_i \nu_{i-1}}{(\rho_{i-1})^2} - \frac{\nu_i \nu_{i+1}}{(\rho_{i+1})^2} \quad (\text{A.2})$$

Le calcul de la moyenne et la variance se déduit alors car $\forall i, E(\nu_i) = 0$.

Moyenne $E(A_1)$:

On obtient $E(A_1) = 1 + \frac{\rho_i}{\rho_{i-1}} + \frac{\rho_i}{\rho_{i+1}}$. D'après l'équation 3.4, on déduit que

$$E(A_1) = 1 + 2 \cos(\alpha) = C_1^{th} \quad (\text{A.3})$$

où on rappelle que $C_k^{th} = 1 + 2 \sum_{j=1}^k \cos(j\alpha)$

Variance $Var(A_1) = E(A_1^2) - E(A_1)^2$:

Ce calcul se fait en utilisant l'expression A.2 de A_1 . En négligeant les termes d'ordre supérieur à 2, on obtient une approximation pour la variance :

$$Var(A_1) \approx (1 - C_1^{th})^2 \frac{\sigma_\rho^2}{\rho_i^2} \quad (\text{A.4})$$

On obtient alors une approximation de l'écart-type de l'erreur pour A_1 :

$$\sigma_{A_1} \approx \left| 1 - C_1^{th} \right| \frac{\sigma_\rho}{\rho_i} = 2 \frac{\sigma_\rho}{\rho_i} \cos(\alpha) \quad (\text{A.5})$$

Finalement, en généralisant pour un voisinage k nous obtenons les résultats suivants :

$$E(A_k) = 1 + 2 \sum_{j=1}^k \cos(j\alpha) = C_k^{th} \quad (\text{A.6})$$

$$Var(A_k) \approx (1 - C_k^{th})^2 \frac{\sigma_\rho^2}{\rho_i^2} \quad (\text{A.7})$$

$$\sigma_{A_k} \approx 2 \frac{\sigma_\rho}{\rho_i} \sum_{j=1}^k \cos(j\alpha) \quad (\text{A.8})$$

Annexe B

Extraction des données observables

B.1 Motivation

Dans les données télémétriques fournies par le capteur, seules la partie des données, représentatives des objets présents sur la route, est utilisée dans le processus de suivi. Il est donc déterminant de différencier les données provenant des véhicules et celles qui sont issues de l'environnement extérieur à la route :

- les méthodes de suivi développées avec utilisation d'un détecteur (SIP-SMC-JPDA, SIP-SMC-PHD, SM-SMC-JPDA, SM-SMC-PHD) ont besoin de ces données pour segmenter les objets. La phase de modélisation qui suit permet alors d'extraire des observations de type centre de gravité des objets.
- les méthodes qui n'utilisent pas le détecteur peuvent, dans leur processus de suivi, considérer l'ensemble des impacts puisque certaines zones restrictives de l'accumulateur sont considérées *a posteriori* dans l'étape de pondération. Il est néanmoins nécessaire d'extraire les données de la zone d'observation pour l'étape de surveillance d'apparition d'objets (initialisation) afin de déterminer si un segment provient bien d'un véhicule ou d'un objet extérieur à la zone d'observation.

Les premières séquences réelles étudiées dans le travail ont pour cadre une ligne droite. D'une manière supervisée, il est possible de connaître les données appartenant à la route en fixant une largeur standard de voie sur laquelle le véhicule porteur évolue. Cette méthode triviale permet un bon étiquetage des données, mais trouve vite ses limites dès lors que la route n'est plus en ligne droite.

Des méthodes de détection de zones d'intérêt basées sur l'utilisation de caméra CCD ou de télémètres existent [CAC99, Zha10]. Les données réelles à disposition rendent impossible l'usage de la caméra comme outil complémentaire (en raison de l'absence de paramètres de calibration). Seules les données télémétriques et les données GPS du véhicule porteur sont exploitables. [FC07] propose une méthode basée sur la seule utilisation du télémètre en étudiant l'alignement des données télémétriques. Ceci permet de construire un histogramme représentatif des impacts qui seraient situés sur un environnement extérieur à la route mais parfaitement structuré. Cette méthode n'est donc

pas applicable dans notre cas puisque l'environnement extérieur du circuit est totalement inconnu. [SFD02] propose d'utiliser les états prédits des objets ainsi que l'incertitude associée pour construire un modèle autour duquel sont attendus l'ensemble des données d'observation. Dans les cas où l'objet est en phase d'apparition ou non-suivi à l'instant précédent, ces données ne seraient pas extraites. Un récapitulatif de l'ensemble des méthodes existantes en utilisant de manière conjointe plusieurs capteurs peut être trouvé dans [BHLLR12].

Nous proposons dans ce manuscrit une méthode d'extraction de données observables basées sur une utilisation conjointe des données GPS du véhicule porteur et de données cartographiques. De telles données sont de plus en plus utilisées dans les systèmes d'assistance à la conduite [FB09, KMCB13]. Connaissant la position du véhicule porteur à chaque instant, son orientation (grâce à ses vitesses latérales et longitudinales) et par projection sur une carte de l'environnement en cours d'acquisition, il est possible de déterminer de manière robuste les données présentes sur la route.

B.2 Données utilisées

B.2.1 Repérage du véhicule porteur

Le véhicule porteur du télémètre est également équipé d'un GPS. Le récepteur permet de fournir des données dans différents systèmes de coordonnées. Des conversions sont nécessaires et font appel à la théorie de la géodésie dont les transformations standard sont présentées dans la section B.3. Les données mises à notre disposition sont :

- la position du récepteur GPS en coordonnées géographiques (latitude, longitude en degrés) dans le système géodésique WGS84 (voir paragraphe B.3 pour la description des systèmes).
- les vitesses latérale et longitudinale sont également connues à chaque instant (données GPS). Celles-ci sont exprimées dans un repère local de coordonnées cartésiennes ENU (« East, North, Up ») fixé en un point de l'espace à proximité du circuit pour l'application P_0^{ENU} .

B.2.2 Données du circuit

Afin de connaître les données du circuit, l'outil OpenStreetMap met librement à disposition un ensemble de données géographiques. Ces données sont regroupées pour une zone d'étude que l'on définit (le circuit). Une carte est constituée de deux éléments fondamentaux :

- les noeuds sont les éléments de base. Ils représentent des coordonnées géographiques (latitude, longitude, élévation) servant à définir tous les points d'intérêts.
- Les chemins sont des connexions entre les noeuds. Ils peuvent alors caractérisés des lignes telles que les routes, les voies ferrées, . . .

La figure B.1 est un exemple des données qui peuvent être extraites de la base OpenStreetMap.

Si on veut utiliser conjointement les données cartes et les données GPS, il est nécessaire de travailler dans un repère commun. On choisit alors de travailler dans un repère cartésien orthonormé.




FIGURE B.1 – Exemple de données issues de la base OpenStreetMap : les nœuds circuit sont représentés en losanges gris au centre de l'image ; d'autres données sont utilisables (bâtiments, routes de natures différentes, ...)

B.3 Systèmes géodésiques

Cette partie présente les notions de base en géodésie (« science qui mesure et représente la surface terrestre »). Un système géodésique est un système de référence permettant d'exprimer les positions au voisinage de la Terre. À un tel système est associé un référentiel. Dans un système géodésique, le référentiel est généralement un repère tridimensionnel orthonormé dont l'origine est à proximité du centre de gravité de la Terre, les axes (Ox) et (Oy) sont dans le plan équatorial terrestre et (Oz) est orienté suivant l'axe de rotation de la Terre. Les coordonnées sont rarement exprimées dans ce référentiel mais celui-ci est nécessaire pour effectuer les transformations. Les coordonnées sont alors des coordonnées cartésiennes (exemple : le repère ECEF « Earth-Centered, Earth-Fixed »).

La Terre est une géoïde. Ce volume ne se prêtant pas aux manipulations mathématiques, elle est alors associée à une ellipsoïde. Des systèmes géodésiques par ellipsoïde sont alors définis (par un centre, un demi-grand axe et un coefficient d'aplatissement). Si la géoïde entière est approchée par une ellipsoïde, on parlera de système géodésique mondial (ou géocentrique puisque référencé par le centre de la Terre). Par exemple, les systèmes ITRS (« International Earth Rotation Service Terrestrial Reference System) ou WGS84 (« World Geodetic System 1984 ») sont des systèmes géodésiques mondiaux.

Dans le cas où le travail se fait sur une partie locale du globe terrestre, la géoïde est alors approchée par une ellipsoïde locale (par un point fondamental sur lequel les deux surfaces sont confondues). Le système géodésique sera alors local. En France, nous utiliserons le système géodésique NTF

(Nouvelle Triangulation de la France).

Dans chaque système, un point de l'espace peut être exprimés sous 3 formes :

- ses coordonnées cartésiennes (abscisse x , ordonnée y , altitude z)
- ses coordonnées géographiques (latitude ϕ , longitude λ , élévation h) (figure B.2).
- ses coordonnées planes ou rectangulaires (abscisse x (parfois notée E), ordonnée y (parfois notée N))

Le passage d'un système à l'autre se fait avec la transformation de leur repère cartésien (7 paramètres : 3 translations, 3 rotations et un facteur d'échelle).




FIGURE B.2 – Illustration des repères spatiaux utilisés pour les coordonnées issues du récepteur GPS : repère local ENU (vert), référentiel ECEF (bleu) et coordonnées WGS84 (orange)

Notre choix pour l'application consiste alors à travailler dans ces systèmes de coordonnées planes de la manière suivante :

- un plan du circuit est déterminé à partir de la récupération des noeuds du circuits sur OpenStreetMap. Des extrémités de segments (représentant les bords de routes) sont alors calculés en coordonnées planes dans un repère local (qu'on dénommera repère ENU) centré sur la position P_0^{ENU} .
- Les impacts laser sont alors exprimés dans ce repère. Pour cela, on utilise les données GPS (positions et vitesses) afin de les calculer en déterminant d'abord les coordonnées cartésiennes du récepteur GPS et donc celles de chaque impact télémétrique. Un test est ensuite effectué pour déterminer si ces données laser sont bien comprises sur une route qui est définie par la zone entre les deux segments extérieurs.

Nous présentons dans la suite du manuscrit les transformations standard qui ont été utilisées pour l'extraction des données observables.

B.4 Extraction des données laser observables

B.4.1 Présentation

Le circuit est représenté par une polyligne définie par un ensemble de noeuds. Ces noeuds représentent le centre de la route pour chaque point de courbure des virages. Pour définir la route, nous allons donc, grâce à une largeur de voie, construire deux segments autour de cette polyligne centrale. Les incertitudes sur les noeuds ne sont pas prises en compte. Pour palier cette imprécision, nous définirons *a posteriori* un seuil de distance pour l'appartenance d'un impact laser en dehors de la route mais très proches des segments extérieurs. Les coordonnées des noeuds sont géographiques (longitude, latitude). Il est donc nécessaire de les transformer en coordonnées planes dans un repère ENU local. Ces transformations des positions GPS du véhicule porteur et des impacts télémétriques sont exprimées dans le même repère : Le processus est schématisé sur la figure B.3 : l'objectif est de transformer les coordonnées géographiques dans le système WGS84 en coordonnées planes dans le système NTF.




FIGURE B.3 – Schématisation des transformations nécessaires pour l'extraction des données observables

B.4.2 Conversion des impacts télémétriques dans le plan

B.4.2.1 Passage des coordonnées géographiques aux coordonnées cartésiennes

Les coordonnées des noeuds de la route (et aussi celles du récepteur GPS) que nous obtenons à chaque instant sont des coordonnées géographiques (λ_W, ϕ_W, h_W) dans le système WGS84. Les coordonnées cartésiennes (X_W, Y_W, Z_W) du récepteur sont alors données par :

$$\begin{cases} X_W = (N + h_W) \cos \phi_W \cos \lambda_W \\ Y_W = (N + h_W) \cos \phi_W \sin \lambda_W \\ Z_W = (N(1 - e^2) + h_W) \sin \phi_W \end{cases} \quad (\text{B.1})$$

Les paramètres utilisés sont :

$$\begin{cases} e = \frac{\sqrt{a^2 - b^2}}{a} \\ N = \frac{a}{\sqrt{1 - e^2 \sin^2 \phi_W}} \text{ grande normale de l'ellipsoïde} \end{cases} \quad (\text{B.2})$$

Les paramètres a et b sont des paramètres de l'ellipsoïde associée au système WGS84 :

- a : demi-grand axe ($a = 6378137\text{m}$)
- b : demi-petit axe ($b = 6356752,31424518 \text{ m}$)

B.4.2.2 Passage du système WGS84 au système NTF

Le passage du système WGS84 au système NTF se fait par application d'une matrice de passage (similitude à 7 paramètres). Le modèle est réduit à 3 paramètres de translation car ni la rotation ni le changement d'échelle n'ont été mis en évidence. Ainsi, les coordonnées cartésiennes d'un point de l'espace sont données dans le système NTF par :

$$\begin{pmatrix} X_N \\ Y_N \\ Z_N \end{pmatrix} = \begin{pmatrix} X_W \\ Y_W \\ Z_W \end{pmatrix} + T_0 \quad (\text{B.3})$$

où T_0 est la position de l'origine du système NTF par rapport à WGS84 avec $T_0 = (168 \ 60 \ -320)^T$.

B.4.2.3 Passage des coordonnées cartésiennes aux coordonnées géographiques

Avant de déterminer les coordonnées planes, il est nécessaire de repasser aux coordonnées géographiques mais cette fois-ci dans le système NTF (λ_N, ϕ_N, h_N) . Celles-ci s'obtiennent en appliquant les équations :

$$\begin{cases} \lambda_N = \arctan\left(\frac{Y_N}{X_N}\right) \\ \phi_N = \arctan\left[\frac{Z_N(1-f) + e^2 a \sin^3 \mu}{(1-f)(\sqrt{X_N^2 + Y_N^2} - e^2 a \cos^3 \mu)}\right] \\ h_N = \sqrt{X_N^2 + Y_N^2} \cos \phi_N + Z_N \sin \phi_N - a \sqrt{1 - e^2 \sin^2 \phi_N} \end{cases} \quad (\text{B.4})$$

avec

$$\mu = \arctan\left[\frac{Z_N}{\sqrt{X_N^2 + Y_N^2}} \left((1-f) + \frac{e^2 a}{\sqrt{X_N^2 + Y_N^2 + Z_N^2}} \right)\right] \quad (\text{B.5})$$

Les paramètres de l'ellipsoïde associée au système NTF (Clarke 1880 IGN) sont :

- a : demi-grand axe ($a = 6378249,2\text{m}$)
- b : demi-petit axe ($b = 6356515,0\text{m}$)
- f : coefficient d'aplatissement ($f = \frac{a-b}{a}$)
- e : première excentricité ($e = \sqrt{\frac{a^2 - b^2}{a^2}}$)

B.4.2.4 Passage des coordonnées géographiques aux coordonnées planes

La dernière étape consiste à obtenir les coordonnées planes du point (x_N, y_N) . Celles-ci sont exprimées dans un repère local centré en un point P_0^{ENU} à proximité de la zone d'étude. Le procédé est constitué d'une projection cartographique des coordonnées géographiques. Dans notre cas, il s'agit d'une projection Lambert I Nord Paris. Les coordonnées sont données par :

$$\begin{cases} x_N = E_0 + R \sin \gamma \\ y_N = N_0 + k_0 \times N \times \cot(\phi_0) - R \cos \gamma \end{cases} \quad (\text{B.6})$$

avec

$$\begin{cases} R = C \exp\left(\frac{-n}{2} \ln \frac{1 + \sin \phi_N}{1 - \sin \phi_N} + \frac{en}{2} \frac{1 + e \sin \phi_N}{1 - e \sin \phi_N}\right) \\ \gamma = n(\lambda_N - \lambda_0) \end{cases} \quad (\text{B.7})$$

Les constantes de Lambert sont données par :

- E_0, N_0 : coordonnées du point d'origine en projection (600000, 200000)m
- ϕ_0 : latitude de l'origine ($\phi_0 = 49^\circ 30'$)
- λ_0 : longitude de l'origine ($\lambda_0 = 2^\circ 20' 14,025''$)
- k_0 : facteur d'échelle à l'origine ($k_0 = 0.99987734$)
- n : exposant de la projection $n = \sin(\phi_0)$
- e : première excentricité de l'ellipsoïde ($e = 0.08248325676$)
- C : constante de projection donnée par :

$$C = k_0 \times N \times \cot(\phi_0) \times \exp\left[n \ln\left(\tan\left(\frac{\pi}{4} + \frac{\phi_0}{2}\right) \times \left(\frac{1 - e \sin(\phi_0)}{1 + e \sin(\phi_0)}\right)^{(e/2)}\right)\right] \quad (\text{B.8})$$

B.4.3 Modélisation de la route

Les différents changements de coordonnées présentés permettent alors de travailler dans un repère cartésien orthonormé pour modéliser la route sur laquelle évolue le véhicule porteur. Le circuit est représenté sous la forme d'une polyligne représentant l'axe de la route. Celle-ci est définie par plusieurs noeuds (points de courbure du circuit) initialement fournis en coordonnées géographiques dans le système WGS84. L'idée est d'exploiter ces informations récupérées sur OpenStreetMap pour

modéliser une zone routière autour de cette polyligne. On note alors *largeur_voie* la largeur modélisée d'une voie de circuit. Notons (x_E^1, y_E^1) et (x_E^2, y_E^2) les coordonnées planes dans le système NTF de deux noeuds consécutifs. Entre ces noeuds, on construit alors deux segments extérieurs (S^i) ($i \in \{1, 2\}$) qui délimitent la route d'équations respectives :

$$(S^i) : \begin{cases} y = \frac{y_E^1 - y_E^2}{y_E^1 - y_E^2} x + y_E^1 - \frac{y_E^1 - y_E^2}{y_E^1 - y_E^2} x_E^1 + (-1)^i \frac{\text{largeur_voie}}{\sin\left(\arctan\left(\frac{x_E^1 - x_E^2}{y_E^1 - y_E^2}\right)\right)} & \text{si } x_E^1 \neq x_E^2 \\ x = x_E^1 + (-1)^i \text{largeur_voie} & \text{sinon} \end{cases} \quad (\text{B.9})$$

Cette construction est faite pour chaque noeud avec celui consécutif. On construit alors des zones d'intérêt et finalement, le circuit est modélisé en intersectant l'ensemble des segments. La figure B.4 montre une portion de circuit ainsi modélisé.




FIGURE B.4 – Exemple de portions de route reconstruites en utilisant les données fournies par OpenStreetMap (noeuds en losanges bleus, axe de la route en pointillés)

B.4.4 Conversion des impacts télémétriques dans le plan

On effectue maintenant le changement de coordonnées pour le récepteur GPS et par la suite pour les impacts laser à chaque instant. L'objectif est de placer tous les impacts dans le repère de la figure B.4 afin de déterminer s'ils sont sur la route ou non.

Le passage des coordonnées en position du récepteur GPS en coordonnées planes du système NTF se fait de la même manière que pour les noeuds. Les coordonnées planes du GPS sont alors notées (x_G, y_G) . L'obtention des coordonnées planes pour chaque impact télémétrique s'obtient en considérant la vitesse du véhicule porteur. Notons pour un instant t donné (V_E^x, V_E^y) les vitesses latérales et longitudinales du véhicule porteur dans le repère local ENU. L'orientation ψ du véhicule porteur doit tenir compte de son sens de déplacement. Elle est donnée par :

$$\psi = \begin{cases} \arctan\left(\left|\frac{y}{x}\right|\right) \operatorname{sgn}(y) & \text{si } x > 0 \\ \frac{\pi}{2} \operatorname{sgn}(y) & \text{si } x = 0 \\ \left(\pi - \arctan\left(\left|\frac{y}{x}\right|\right)\right) \operatorname{sgn}(y) & \text{si } x < 0 \end{cases} \quad (\text{B.10})$$


Les récepteurs GPS et le capteur télémétrique ne sont pas installés aux mêmes endroits sur le véhicule. On note (x_{GT}, y_{GT}) la translation permettant de passer du repère centré sur le GPS et orienté dans le sens de déplacement du véhicule au repère centré sur le télémètre et orienté de la même manière. En tenant compte de cette translation, un impact télémétrique de coordonnées (ρ, θ) dans le repère du télémètre a des coordonnées planes (x_{imp}, y_{imp}) dans le repère local ENU données via l'utilisation des coordonnées homogènes :

$$\begin{pmatrix} x_{imp} \\ y_{imp} \\ 1 \end{pmatrix} = \begin{pmatrix} \cos \psi & \sin \psi & x_G \\ -\sin \psi & \cos \psi & y_G \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} 0 & 1 & x_{GT} \\ -1 & 0 & y_{GT} \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \rho \cos \theta \\ \rho \sin \theta \\ 1 \end{pmatrix} \quad (\text{B.11})$$


La zone d'observation (la route) et chaque impact étant dans un repère cartésien orthonormé, il devient alors trivial de décider si l'impact provient d'un objet présent sur la route ou de l'environnement extérieur à celle-ci.

B.4.5 Résultats et discussions


La solution développée est appliquée à l'ensemble des impacts télémétriques de chaque instant. Les figures B.5 illustrent pour différentes acquisitions les résultats de ces conversions : les données détectées dans la zone d'observation apparaissent en rouge, celles dans l'environnement extérieur en noir et la position du récepteur GPS en vert. La méthode permet, même en cas de virages à faible rayon de courbure qui sont approximés par une série de segments, d'extraire les données observables. La figure B.5(c) montre un cas limite où en raison de l'incertitude associée à la carte et aux données issues du récepteur GPS, quelques impacts n'ont pas été conservés (extrémité du véhicule rouge le plus proche du récepteur GPS). Dans ce cas précis, le filtre doit alors être capable de gérer ce cas d'occultation très partielle. À l'inverse, des données peuvent être étiquetées en tant que données observables alors qu'elles représentent en fait des éléments extérieurs très proches de la route (notamment pour des barrières de sécurité par exemple). La notion de clutter est dans ce cas parfaitement illustrée. Il s'agit d'objets qui ont une existence physique mais qui ne représentent pas des véhicules.



(a)



(b)



(c)

FIGURE B.5 – Exemple de 3 acquisitions traitées pour l'extraction de données observables : (a) cas d'un virage fort (scan #1) (b) cas de ligne droit (scan #351) (c) cas à problème (scan #1802)

Bibliographie

- [Abu05] Iyad Abuhadrous, *Système embarqué temps réel de localisation et de modélisation 3D par fusion multi-capteur*, Ph.D. thesis, École des Mines de Paris, 2005.
- [Ada01] M.D. Adams, *On-line gradient based surface discontinuity detection for outdoor scanning range sensors*, IEEE/RSJ International Conference on Intelligent Robots and Systems, vol. 3, 2001, pp. 1726–1731.
- [AFG06] F. Amigoni, G. Fontana, and F. Garigiola, *A method for building small-size segment-based maps*, Distributed Autonomous Robotic Systems 7 (Maria Gini and Richard Voyles, eds.), Springer Japan, 2006, pp. 11–20.
- [AG08] F. Amigoni and S. Gasparini, *Analysis of methods for reducing line segments in maps : Towards a general approach*, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), sept. 2008, pp. 2896–2901.
- [AGB08] Fahed Abdallah, Amadou Gning, and Philippe Bonnifait, *Box particle filtering for nonlinear state estimation using interval analysis*, Automatica **44** (2008), no. 3, 807–815.
- [AKLO10] S.-Y. An, J.-G. Kang, L.-K. Lee, and S.-Y. Oh, *SLAM with salient line feature extraction in indoor environments*, 11th International Conference on Control Automation Robotics Vision (ICARCV), dec. 2010, pp. 410–416.
- [Ale04] A. Alempijevic, *High-speed feature extraction in sensor coordinates for laser range-finders*, Australasian Conference on Robotics and Automation (Canberra, Australia), 2004.
- [AM79] B.D.O Anderson and J.B. Moore, *Optimal filtering*, Prentice Hall, 1979.
- [AMGC02] M.S. Arulampalam, S. Maskell, N. Gordon, and T. Clapp, *A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking*, IEEE Trans. on Signal Processing **50** (2002), no. 2, 174–188.
- [Arr98] K.A. Arras, *An introduction to error propagation : Derivation, meaning and examples of equation*, Tech. Report EPFL-ASL-TR-98-01, Autonomous Systems Lab, Institute of Robotic Systems, EPFL, 1998.
- [AVMS08] Gorji Daronkolaei Aliakbar, Nazari Vahid, Bagher Menjah Mohammad, and Shiry Saeed, *A joint probability data association filter algorithm for multiple robot tracking problems*, Tools in Artificial Intelligence **10** (2008), 163–186.

- [AZF11] M. Awrangjeb, Chunsun Zhang, and C.S. Fraser, *Automatic reconstruction of building roofs using LIDAR and multispectral imagery*, International Conference on Digital Image Computing Techniques and Applications (DICTA), dec. 2011, pp. 370–375.
- [BA00] G.A. Borges and M.-J. Aldon, *A split-and-merge segmentation algorithm for line extraction in 2D range images*, International Conference on Pattern Recognition, vol. 1, 2000, pp. 441–444.
- [BA04] G.A. Borges and M.J. Aldon, *Line extraction in 2D range images for mobile robotics*, Journal of Intelligent and Robotic Systems **40** (2004), no. 3, 267–297.
- [BA12] M. Beard and S. Arulampalam, *Performance of PHD and CPHD filtering versus JIPDA for bearings-only multi-target tracking*, 15th International Conference on Information Fusion (FUSION), july 2012, pp. 542–549.
- [BDH03] M. Bolic, P.M. Djuric, and S. Hong, *New resampling algorithms for particle filters*, IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), vol. 2, April 2003, pp. 589–92.
- [Ber99] N. Bergman, *Recursive bayesian estimation. Navigation and tracking applications.*, Ph.D. thesis, Linkoping Universitet, 1999.
- [Bes99] P. Besesty, *Télémètre à laser puce*, Tech. Report R1811_03_1999, Techniques de l'ingénieur, March 1999, Online : accessed 15-November-2012.
- [BHLLR12] Aharon Bar Hillel, Ronen Lerner, Dan Levi, and Guy Raz, *Recent progress in road and lane detection : a survey*, Machine Vision and Applications (2012), 1–19.
- [Bla86] S. S. Blackman, *Multiple-target tracking with radar applications*, 1986.
- [BLK12] O. Barinova, V. Lempitsky, and P. Kholi, *On detection of multiple object instances using Hough transforms*, IEEE Transactions on Pattern Analysis and Machine Intelligence **34** (2012), no. 9, 1773–1784.
- [BOOCB12] J.S. Berrio, S. Orozco Ordonez, and E. Caicedo Bravo, *Lines extraction in laser scans through the integration of the Hough transform and sef*, Workshop on Engineering Applications (WEA), may 2012, pp. 1–6.
- [BP99] S.S. Blackman and R. Popoli, *Design and analysis of modern tracking systems*, Artech House radar library, Artech House, 1999.
- [BPB12] J.S. Berrio, L.M. Paz, and E.C. Bravo, *Segmentation and parameterization of 2D lines based on mean shift clustering*, Workshop on Engineering Applications (WEA), may 2012, pp. 1–6.
- [BRL⁺09] M.D. Breitenstein, F. Reichlin, B. Leibe, E. Koller-Meier, and L. Van Gool, *Robust tracking-by-detection using a detector confidence particle filter*, IEEE 12th International Conference on Computer Vision, 2009, pp. 1515–1522.

-
- [BSBF07] Y. Bar-Shalom, S.S. Blackman, and R.J. Fitzgerald, *Dimensionless score function for multiple hypothesis tracking*, IEEE Transactions on Aerospace and Electronic Systems **43** (2007), no. 1, 392–400.
- [BSF87] Y. Bar-Shalom and T.-E. Fortmann, *Tracking and data association*, Academic Press, Inc., 1987.
- [BSL93] Y. Bar-Shalom and X.-R. Li, *Estimation and tracking : Principles, techniques and software*, Artech House, 1993.
- [BSL95] Y. Bar-Shalom and X.R. Li, *Multitarget multisensor tracking : Principles and techniques*, YBS Publishing, 1995.
- [CAC99] R. Chapuis, R. Aufrere, and F. Chausse, *Recovering the 3D shape of a road by vision*, Seventh International Conference on Image Processing and Its Applications, vol. 2, 1999, pp. 686–690.
- [CB05] D.E. Clark and J. Bell, *Data association for the PHD filter*, International Conference on Intelligent Sensors, Sensor Networks and Information Processing, dec. 2005, pp. 217–222.
- [CB08] N. Chehata and F. Bretar, *Terrain modeling from lidar data : Hierarchical K-means filtering and Markovian regularization*, 15th IEEE International Conference on Image Processing (ICIP), oct. 2008, pp. 1900–1903.
- [CCF99] J. Carpenter, P. Clifford, and P. Fearnhead, *Improved particle filter for nonlinear problems*, IEE Proceedings Radar, Sonar and Navigation **146** (1999), no. 1, 2–7.
- [CDF07] J. Chen, S. Deutschle, and K. Fuerstenberg, *Evaluation methods and results of the INTERSAFE intersection assistants*, IEEE Intelligent Vehicles Symposium, june 2007, pp. 142–147.
- [CDMMS97] H Carvalho, P Del Moral, A Monin, and G Salut, *Optimal nonlinear filtering in GPS/INS integration*, IEEE Transactions on Aerospace and Electronic Systems **33** (1997), no. 3, 835–850.
- [CH96] I.J. Cox and S.L. Hingorani, *An efficient implementation of Reid’s multiple hypothesis tracking algorithm and its evaluation for the purpose of visual tracking*, IEEE Transactions on Pattern Analysis and Machine Intelligence **18** (1996), no. 2, 138–150.
- [Che95] Y. Cheng, *Mean shift, mode seeking, and clustering*, IEEE Transactions on Pattern Analysis and Machine Intelligence **17** (1995), no. 8, 790–799.
- [Che03] Zhe Chen, *Bayesian filtering : From Kalman filters to particle filters, and beyond*, 2003.
- [Cla06] D.E. Clark, *Multiple target tracking with the Probability Hypothesis Density filter*, Ph.D. thesis, Department of Electrical Engineering, Heriot-Watt University, Edinburgh, U.K., october 2006.

- [CM02] D. Comaniciu and P. Meer, *Mean shift : a robust approach toward feature space analysis*, IEEE Transactions on Pattern Analysis and Machine Intelligence, **24** (2002), no. 5, 603–619.
- [CRPB07] D. Clark, I.T. Ruiz, Y. Petillot, and J. Bell, *Particle PHD filter multiple target tracking in sonar image*, IEEE Transactions on Aerospace and Electronic Systems **43** (2007), no. 1, 409–416.
- [CT96] J.A. Castellanos and J.D. Tardos, *Robotics and manufacturing : Recent trends in research and applications*, vol. 6, ch. Laser-based Segmentation and Localization for a Mobile Robot, pp. 101–108, ASME Press, 1996.
- [CV07] D. Clark and B.-N. Vo, *Convergence analysis of the gaussian mixture PHD filter*, IEEE Transactions on Signal Processing **55** (2007), no. 4, 1204–1212.
- [CWS⁺11] D.F. Crouse, P. Willett, L. Svensson, D. Svensson, and M. Guerriero, *The set MHT*, International Conference on Information Fusion (FUSION), july 2011, pp. 1–8.
- [CZZS07] J. Cui, H. Zha, H. Zhao, and R. Shibasaki, *Laser-based detection and tracking of multiple people in crowds*, Computer Vision and Image Processing **106** (2007), no. 3.
- [DDFG01] A. Doucet, N. De Freitas, and N. Gordon, *Sequential Monte Carlo methods in practice*, Springer, New York ; London, 2001.
- [DdFMR00] A. Doucet, N. de Freitas, K. Murphy, and S. Russell, *Rao-Blackwellised Particle Filtering for Dynamic Bayesian Networks*, Proceedings of the Sixteenth Conference Annual Conference on Uncertainty in Artificial Intelligence (UAI) (San Francisco, CA), Morgan Kaufmann, 2000, pp. 176–183.
- [DEMG12] C. Degen, H. El Mokni, and F. Govaers, *Evaluation of a coupled laser inertial navigation system for pedestrian tracking*, 15th International Conference on Information Fusion (FUSION), 2012, pp. 1292–1299.
- [DF90] R. Deriche and O. Faugeras, *Tracking line segments*, Image and Vision Computing **8** (1990), no. 4, 261–270.
- [DGA00] A. Doucet, S. Godsill, and C. Andrieu, *On Sequential Monte Carlo Sampling Methods for Bayesian Filtering*, Statistics and Computing **10** (2000), no. 3, 197–208.
- [DH71] R.O. Duda and P.E. Hart, *Use of the Hough transformation to detect lines and curves in pictures*, Tech. Report 36, AI Center, SRI International, Apr 1971, SRI Project 8259 Comm. ACM, Vol 15, No. 1.
- [DH73] ———, *Pattern classification and scene analysis*, 1 ed., John Wiley & Sons Inc, February 1973.
- [DKF⁺05] K. Dietmayer, N. Kämpchen, K. Fürstenberg, J. Kibbel, W. Justus, and R. Schulz, *Roadway detection and lane detection using multilayer laserscanner*, Advanced Microsystems for Automotive Applications (Jürgen Valldorf and Wolfgang Gessner,

-
- eds.), *Advanced Microsystems for Automotive Applications 2005*, Springer Berlin Heidelberg, 2005, pp. 197–213.
- [DM04] P. Del Moral, *Feynman-kac formulae : Genealogical and interacting particle systems with applications*, Springer series in statistics : Probability and its applications, Springer, 2004.
- [DMDJ06] P. Del Moral, A. Doucet, and A. Jasra, *Sequential Monte Carlo samplers*, Journal of the Royal Statistical Society : Series B (Statistical Methodology) **68** (2006), no. 3, 411–436.
- [DMNRS92] P Del Moral, J.-C. Noyer, G. Rigal, and G Salut, *Traitement particulière du signal RADAR : détection, estimation et reconnaissance de cibles aériennes*, Tech. report, Rapport LAAS no 92495, 1992.
- [DMNRS93] P. Del Moral, J.-C. Noyer, G. Rigal, and G Salut, *Traitement non-linéaire du signal par réseau particulière*, 14ème colloque GRETSI (Juan-les-Pins), sept. 1993, pp. 399–402.
- [DOA⁺11] R. Dominguez, E. Onieva, J. Alonso, J. Villagra, and C. Gonzalez, *LIDAR based perception solution for autonomous vehicles*, 11th International Conference on Intelligent Systems Design and Applications (ISDA), nov. 2011, pp. 790 –795.
- [Dou98] A. Doucet, *On Sequential Simulation-Based Methods for Bayesian Filtering*, Tech. Report CUED/F-INFENG/TR. 310, Cambridge University Department of Engineering, 1998.
- [DPD⁺12] J. Deschaud, D. Prasser, M.F. Dias, B. Browning, and P. Rander, *Automatic data driven vegetation modeling for lidar simulation*, IEEE International Conference on Robotics and Automation (ICRA), may 2012, pp. 5030 –5036.
- [DRBU09] M.S. Darms, P.E. Rybski, C. Baker, and C. Urmson, *Obstacle detection and tracking for the urban challenge*, IEEE Transactions on Intelligent Transportation Systems **10** (2009), no. 3, 475 –485.
- [DSS01] K. Dietmayer, J. Sparbert, and D. Steller, *Model based object classification and tracking in traffic scenes from range images*, International Conference on Information Visualisation, 2001.
- [EW00] A. Ewald and V. Willhoeft, *Laser scanners for obstacle detection in automotive applications*, IEEE Intelligent Vehicles Symposium (IV), 2000, pp. 682 –687.
- [EWBS05] O. Erdinc, P. Willett, and Y. Bar-Shalom, *Probability hypothesis density filter for multitarget multisensor tracking*, 8th International Conference on Information Fusion, vol. 1, july 2005.
- [FB81] M. Fischler and R. Bolles, *Random sample consensus : a paradigm for model fitting with application to image analysis and automated cartography*, Communications of the ACM **24** (1981), no. 6, 381–395.

- [FB09] C. Fouque and P. Bonnifait, *On the use of 2D navigable maps for enhancing ground vehicle localization*, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2009, pp. 1885–1890.
- [FBSS83] T.E. Fortmann, Y. Bar-Shalom, and M. Scheffe, *Sonar tracking of multiple targets using joint probabilistic data association*, IEEE journal of Oceanic Engineering **OE-8** (1983), no. 3, 173–184.
- [FC07] F. Fayad and V. Cherfaoui, *Tracking objects using a laser scanner in driving situation based on modeling target shape*, IEEE Intelligent Vehicles Symposium, june 2007, pp. 44–49.
- [FD03] K.Ch. Fuerstenberg and M. Dittmer, *Data fusion and ego-motion estimation using laserscanners*, IEEE Intelligent Transportation Systems (ITS), vol. 2, oct. 2003, pp. 1224 – 1228.
- [FD04] K.Ch. Fuerstenberg and K. Dietmayer, *Object tracking and classification for multiple active safety and comfort applications using a multilayer laser scanner*, IEEE Intelligent Vehicles Symposium, june 2004, pp. 802 – 807.
- [FDEW02] K.Ch. Fuerstenberg, K.C.J. Dietmayer, S. Eisenlauer, and V. Willhoeft, *Multilayer laserscanner for robust object tracking and classification in urban*, 9th World Congress on Intelligent Transport Systems (ITS), 2002, pp. 7–8.
- [FL03] K.Ch. Fuerstenberg and U. Lages, *Pedestrian detection and classification by laserscanners*, In Procs. IEEE Intelligent Vehicles Symposium, 2003.
- [FLN12a] B. Fortin, R. Lherbier, and J.-C. Noyer, *Feature extraction in scanning laser range data using invariant parameters : application to vehicle detection*, IEEE Transactions on Vehicular Technology **61** (2012), no. 9, 3838 – 3850.
- [FLN12b] ———, *A particle filtering approach for joint vehicular detection and tracking in lidar data*, IEEE International Instrumentation and Measurement Technology Conference (I2MTC) (Graz, Austria), May 2012, pp. 391–396.
- [FLN13a] ———, *Dynamic estimation from distributed measurements using the RFS theory*, Numerical Analysis and Scientific Computation with Applications (NASCA) (Calais, France), June 2013, p. 43.
- [FLN13b] ———, *A labeled PHD filter for extended target tracking in lidar data using geometric invariance properties : vehicular application*, 16th International Conference on Information Fusion (FUSION) (Istanbul, Turkey), July 2013, 1744-1751.
- [FLN13c] ———, *A PHD approach for multiple vehicle tracking based on a polar detection method in laser range data*, IEEE International Systems Conference (SysCon) (Orlando, Florida, USA), April 2013, pp. 262–268.
- [FMCV10] C. Fernández, V. Moreno, B. Curto, and J. A. Vicente, *Clustering and line detection in laser range measurements*, Robotics and Autonomous Systems **58** (2010), no. 5, 720 – 726.

-
- [FP03] D. A. Forsyth and J. Ponce, *Computer vision : A modern approach*, Prentice Hall, 2003.
- [Fre99] J.F.G. De Freitas, *Bayesian methods for neural networks*, Tech. report, 1999.
- [Fue05] K.Ch. Fuerstenberg, *A new European approach for intersection safety - the EC-Project INTERSAFE*, IEEE Intelligent Transportation Systems, sept. 2005, pp. 432 – 436.
- [FW01] K.Ch. Fuerstenberg and V. Willhoeft, *Object tracking and classification using laserscanners-pedestrian recognition in urban environment*, IEEE Intelligent Transportation Systems, 2001, pp. 451 –453.
- [FW05] K.Ch. Fuerstenberg and T. Weiss, *Feature-level map building and object recognition for intersection safety applications*, IEEE Intelligent Vehicles Symposium (IV), june 2005, pp. 490 – 495.
- [GBL02] H. Gonzalez-Banos and J.-C. Latombe, *Navigation strategies for exploring indoor environments*, The International Journal of Robotics Research **21** (2002), no. 10, 829–848.
- [GDW⁺01] Simon Godsill, Arnaud Doucet, Mike West, Ann Inst, Statist Math, Monte Carlo, and Particle Filters, *Maximum a posteriori sequence estimation using Monte Carlo particle filters*, 2001.
- [GG84] S. Geman and D. Geman, *Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images*, IEEE Transactions on Pattern Analysis and Machine Intelligence **PAMI-6** (1984), no. 6, 721 –741.
- [GGB⁺02] F. Gustafsson, F. Gunnarsson, N. Bergman, U. Forssell, J. Jansson, R. Karlsson, and P.-J. Nordlund, *Particle filters for positioning, navigation, and tracking*, IEEE Transactions on Signal Processing **50** (2002), no. 2, 425 –437.
- [GLO11] K. Granström, C. Lundquist, and U. Orguner, *Tracking rectangular and elliptical extended targets using laser measurements*, 14th International Conference on Information Fusion (FUSION), july 2011, pp. 1 –8.
- [GLO12] K. Granström, C. Lundquist, and O. Orguner, *Extended target tracking using a gaussian-mixture PHD filter*, IEEE Transactions on Aerospace and Electronic Systems **48** (2012), no. 4, 3268 –3286.
- [GM07] A. Gorji and M.B. Menhaj, *Multiple target tracking for mobile robots using the JP-DAF algorithm*, 19th IEEE International Conference on Tools with Artificial Intelligence, vol. 1, oct. 2007, pp. 137–145.
- [GSB07] G. Grisetti, C. Stachniss, and W. Burgard, *Improved techniques for grid mapping with Rao-Blackwellized particle filters*, IEEE Transactions on Robotics **23** (2007), no. 1, 34 –46.

- [GSS93] N.J. Gordon, D.J. Salmond, and A.F.M. Smith, *Novel approach to nonlinear/non-Gaussian Bayesian state estimation*, IEEE Proceedings F Radar and Signal Processing **140** (1993), no. 2, 107–113.
- [GW12] R. Georgescu and P. Willett, *The multiple model CPHD tracker*, IEEE Transactions on Signal Processing **60** (2012), no. 4, 1741–1751.
- [GZLB10] L. Gong, Y. Zhang, Z. Li, and Q. Bao, *Automated road extraction from LiDAR data based on intensity and aerial photo*, 3rd International Congress on Image and Signal Processing (CISP), vol. 5, oct. 2010, pp. 2130–2133.
- [HBCB12] A. Houenou, P. Bonnifait, V. Cherfaoui, and J.-F. Boissou, *A track-to-track association method for automotive perception systems*, IEEE Intelligent Vehicles Symposium (IV), 2012, pp. 704–710.
- [HCP02] C. Hue, J.-P. Le Cadre, and P. Perez, *Sequential monte carlo methods for multiple target tracking and data fusion*, IEEE Transactions on Signal Processing **50** (2002), no. 2, 309–325.
- [Hou59] P. V. C. Hough, *Machine analysis of bubble chamber pictures*, International Conference on High Energy Accelerators and Instrumentation (CERN), 1959.
- [HS07] A. Harati and R. Siegwart, *A new approach to segmentation of 2D range scans into linear regions*, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2007, pp. 2083–2088.
- [HSG06] Jeroen D. Hol, Thomas B. Schön, and Fredrik Gustafson, *On resampling algorithms for particle filters*, IEEE Non linear Statistical Signal Processing Workshop (Cambridge, UK), Sept 2006, pp. 79–82.
- [HTK⁺11] B.K. Habtemariam, R. Tharmarasa, T. Kirubarajan, D. Grimmett, and C. Wakayama, *Multiple detection probabilistic data association filter for multistatic target tracking*, 14th International Conference on Information Fusion (FUSION), july 2011, pp. 1–6.
- [IOS12] L. Iftekhar and R. Olfati-Saber, *Autonomous driving for vehicular networks with nonlinear dynamics*, IEEE Intelligent Vehicles Symposium (IV), june 2012, pp. 723–729.
- [Jid08] B. Jida, *Intégration du contexte par réseaux bayésiens pour la détection et le suivi multi-cibles*, Ph.D. thesis, Université du Littoral Côte d’Opale, 2008.
- [JMF99] A. K. Jain, M. N. Murty, and P. J. Flynn, *Data clustering : a review*, ACM Computing Surveys **31** (1999), no. 3, 264–323.
- [JN11] F. Jiménez and J.E. Naranjo, *Improving the obstacle detection and identification algorithms of a laserscanner-based collision avoidance system*, Transportation Research Part C : Emerging Technologies **19** (2011), no. 4, 658–672.
- [JU97] S.J. Julier and J.K. Uhlmann, *A new extension of the Kalman filter to nonlinear systems*, SPIE Aerosense Symposium (Orlando), April 1997.

-
- [Kal60] R.S. Kalman, *A new approach to linear filtering and prediction problems*, Transactions of the ASME, Series D. Journal of Basic Engineering **82** (1960), 35–45.
- [KKI05] C. Kreucher, K. Kastella, and A.O. Hero III, *Multitarget tracking using a particle filter representation of the joint multitarget density*, IEEE Transactions on Aerospace and Electronic Systems, 2005.
- [KKKR13] Bahador Khaleghi, Alaa Khamis, Fakhreddine O. Karray, and Saiedeh N. Razavi, *Multisensor data fusion : A review of the state-of-the-art*, Information Fusion **14** (2013), no. 1, 28 – 44.
- [KLW94] A. Kong, J.S. Liu, and W.H. Wong, *Sequential imputations and bayesian missing data problems*, Journal of the American Statistical Association **89** (1994), 278–288.
- [KLW⁺10] B. Kalyan, K.W. Lee, S. Wijesoma, D. Moratuwage, and N.M. Patrikalakis, *A random finite set based detection and tracking using 3D lidar in dynamic environments*, IEEE International Conference on Systems Man and Cybernetics (SMC), oct. 2010, pp. 2288 –2292.
- [KM08] A.Y. Kibangou and A. Monin, *GPS based land vehicle positioning using gaussian sum filters*, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2008), 2008, pp. 3653–3656.
- [KMCB13] Marek Kurdej, Julien Moras, Véronique Cherfaoui, and Philippe Bonnifait, *Controlling remanence in evidential grids using geodata for dynamic scene perception*, International Journal of Approximate Reasoning (2013), (in press).
- [KPL05] C.T.M. Keat, C. Pradalier, and C. Laugier, *Vehicle detection and car park mapping using laser scanner*, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), aug. 2005, pp. 2054 – 2060.
- [KR08] P. Kmiotek and Y. Ruichek, *Multisensor fusion based tracking of coalescing objects in urban environment for an autonomous vehicle navigation*, IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (Seoul, Korea), 2008, pp. 52–57.
- [LAC97] J.-L. Lacoume, P.-O. Amblard, and P. Comon, *Statistiques d’ordre supérieur pour le traitement du signal*, Masson, 1997.
- [LBSK06] L. Lin, Y. Bar-Shalom, and T. Kirubarajan, *Track labeling and PHD filter for multi-target tracking*, IEEE Transactions on Aerospace and Electronic Systems **42** (2006), no. 3, 778–795.
- [LCB12] L. Lamard, R. Chapuis, and J.-P. Boyer, *A comparison of two different tracking algorithms is provided for real application*, IEEE Intelligent Vehicles Symposium (IV), june 2012, pp. 414 –419.
- [LCB13] ———, *Multi target tracking with CPHD filter based on asynchronous sensors*, 16th International Conference on Information Fusion (FUSION), 2013.

- [LJNW09] R. Lherbier, B. Jida, J.-C. Noyer, and M. Wahl, *Use of contextual information by bayesian networks for multi-object tracking in scanning laser range data*, 9th International Conference on Intelligent Transport Systems Telecommunications (ITST), oct. 2009, pp. 97–102.
- [LM94] F. Lu and E. Milios, *Robot pose estimation in unknown environments by matching 2D range scans*, Journal of Intelligent and Robotic Systems **18** (1994), 249–275.
- [LO10] Y. Li and E.B. Olson, *Extracting general-purpose features from LIDAR data*, IEEE International Conference on Robotics and Automation (ICRA), may 2010, pp. 1388–1393.
- [LS11] Christian Lundquist and Thomas B. Schön, *Joint ego-motion and road geometry estimation*, Information Fusion **12** (2011), no. 4, 253–263.
- [LWM11] J. Liu, W. Wang, and F. Ma, *A regularized auxiliary particle filtering approach for system state estimation and battery life prediction*, Smart Materials and Structures **20** (2011), no. 7.
- [Mah97] R. Mahler, *Random sets : theory and applications*, IMA volumes in mathematics and its applications, ch. Random Sets in Information : An Overview, pp. 129–164, Springer, 1997.
- [Mah03] R.P.S. Mahler, *Multitarget Bayes filtering via first-order multitarget moments*, IEEE Transactions on Aerospace and Electronic Systems **39** (2003), no. 4, 1152–1178.
- [Mah04] R. Mahler, *A theory of PHD filter of higher order in target number*, Proc. SPIE Defense Security Symp. Signal Process., Sensor Fusion, Target Recognition XV, vol. 6235, April 2004.
- [Mah07] ———, *PHD filters of higher order in target number*, IEEE Transactions on Aerospace and Electronic Systems **43** (2007), no. 4, 1523–1543.
- [Mah09] ———, *PHD filters for nonstandard targets, i : Extended targets*, 12th International Conference on Information Fusion (FUSION), july 2009, pp. 915–921.
- [MCCTM06] R. Martinez-Cantin, J.A. Castellanos, J.D. Tardos, and J.M.M. Montiel, *Adaptive scale robust segmentation for 2D laser scanner*, IEEE/RSJ International Conference on Intelligent Robots and Systems, oct. 2006, pp. 796–801.
- [ME04] D. Musicki and R. Evans, *Joint integrated probabilistic data association : JIPDA*, IEEE Transactions on Aerospace and Electronic Systems **40** (2004), no. 3, 1093–1099.
- [MM06] R.A. MacLachlan and C. Mertz, *Tracking of moving objects from a moving vehicle using a scanning laser rangefinder*, IEEE Intelligent Transportation Systems Conference (ITSC), sept. 2006, pp. 301–306.
- [MML06] J. Minguez, L. Montesano, and F. Lamiroux, *Metric-based iterative closest point scan matching for sensor displacement estimation*, IEEE Transactions on Robotics **22** (2006), no. 5, 1047–1054.

-
- [MNBSV06] J. Melo, A. Naftel, A. Bernardino, and J. Santos-Victor, *Detection and classification of highway lanes using vehicle motion trajectories*, IEEE Transactions on Intelligent Transportation Systems **7** (2006), no. 2, 188 – 200.
- [MNRS95] P. Del Moral, J.-C. Noyer, G. Rigal, and G. Salut, *Résolution particulière et traitement non-linéaire du signal : Applications Radar/Sonar*, Traitement du Signal **12** (1995), no. 4, 287–301.
- [MOL01] C. Musso, N. Oudjane, and FranÇ. Legland, *Improving regularized particle filters*, Sequential Monte Carlo Methods in Practice. New York (A. Doucet, N. de Freitas, and N. Gordon, eds.), no. 12, Statistics for Engineering and Information Science, 2001, pp. 247–271.
- [Mon03] A Monin, *Submarine floating antenna model for LORAN-C signal processing*, IEEE Transactions on Aerospace and Electronic **39** (2003), no. 4, 1304–1316.
- [MRD12] D. Meissner, S. Reuter, and K. Dietmayer, *Real-time detection and tracking of pedestrians at intersections using a network of laserscanners*, IEEE Intelligent Vehicles Symposium (IV), june 2012, pp. 630 –635.
- [MRR⁺53] N. Metropolis, A.W. Rosenbluth, M.N. Rosenbluth, A.H. Teller, and E. Teller, *Equation of state calculations by fast computing machines*, Journal of Chemical Physics **21** (1953), 1087–1092.
- [MVAV11] J. Mullane, B.-N. Vo, M.D. Adams, and B.-T. Vo, *A Random-Finite-Set Approach to Bayesian SLAM*, IEEE Transactions on Robotics **27** (2011), no. 2, 268 –282.
- [MVV08] P. Muthumanikandan, S. Vasuhi, and V. Vaidehi, *Multiple maneuvering target tracking using MHT and nonlinear non-gaussian Kalman filter*, International Conference on Signal Processing, Communications and Networking (ICSCN), jan. 2008, pp. 52 –56.
- [MVV11] R.P.S. Mahler, B.-T. Vo, and B.-N. Vo, *CPHD filtering with unknown clutter rate and detection profile*, 14th International Conference on Information Fusion (FUSION), july 2011, pp. 1–8.
- [NB08] F. Nashashibi and A. Bargeton, *Laser-based vehicles tracking and classification using occlusion reasoning and confidence estimation*, Intelligent Vehicles Symposium, june 2008, pp. 847 –852.
- [NGM⁺07] V. Nguyen, S. Gätcher, A. Martinelli, N. Tomatis, and R. Siegwart, *A comparison of line extraction algorithms using 2D range data for indoor mobile robotics*, Autonomous Robot **23** (2007), 97–111.
- [NLF10] J.-C. Noyer, R. Lherbier, and B. Fortin, *Automatic feature extraction in laser rangefinder data using geometric invariance*, IEEE Forty Fourth Asilomar Conference on Signals, Systems and Computers (Pacific Grove, California, USA), nov. 2010, pp. 199–203.

- [NPKJ08] T.T. Nguyen, X.D. Pham, D. Kim, and J.W. Jeon, *A test framework for the accuracy of line detection by Hough Transforms*, IEEE International Conference on Industrial Informatics (INDIN), july 2008, pp. 1528 –1533.
- [NYSJ09] M. Norouzi, M. Yaghoobi, M.R. Siboni, and M. Jadaliha, *Recursive line extraction algorithm from 2D laser scanner applied to navigation a mobile robot*, IEEE International Conference on Robotics and Biomimetics, feb. 2009, pp. 2127 –2132.
- [OLG11] U. Orguner, C. Lundquist, and K. Granström, *Extended target tracking with a cardinalized probability hypothesis density filter*, 14th International Conference on Information Fusion (FUSION), July 2011, pp. 65–72.
- [Pac11] Michele Pace, *Stochastic models and methods for multi-object tracking*, Ph.D. thesis, INRIA Bordeaux, July 2011.
- [PBNVC06] K. Panta, Ba-Ngu-Vo, and D.E. Clark, *An efficient track management scheme for the gaussian-mixture probability hypothesis density tracker*, Fourth International Conference on Intelligent Sensing and Information Processing (ICISIP), 15 2006-dec. 18 2006, pp. 230–235.
- [PDM13] M. Pace and P. Del Moral, *Mean-field PHD filters based on generalized Feynman-Kac flow*, IEEE Journal of Selected Topics in Signal Processing Special Issue on Multi-Target Tracking (2013), no. 99.
- [PHO07] N.T. Pham, W. Huang, and S.H. Ong, *Tracking multiple objects using probability hypothesis density filter and color measurements*, IEEE International Conference on Multimedia and Expo, july 2007, pp. 1511 –1514.
- [PLWG10] N.T. Pham, K. Leman, M. Wong, and F. Gao, *Combining JPDA and particle filter for visual tracking*, IEEE International Conference on Multimedia and Expo (ICME), july 2010, pp. 1044–1049.
- [PN05] C. Premebida and U. Nunes, *Segmentation and geometric primitives extraction from 2D laser range data for mobile robot applications*, 4th Nat. Festival of Robotics Scientific Meeting (ROBOTICA) (Coimbra, Portugal), 2005, pp. 17–25.
- [PRB03] S.T. Pfister, S.I. Roumeliotis, and J.W. Burdick, *Weighted line fitting algorithms for mobile robot map building and efficient data representation*, IEEE International Conference on Robotics and Automation (ICRA), vol. 1, sept. 2003, pp. 1304 – 1311.
- [PRO] *Site du projet prometheus*, <http://www.eurekanetwork.org/project/-/id/45>, Online : accessed 25-November-2013.
- [PT09] A. Petrovskaya and S. Thrun, *Model based vehicle detection and tracking for autonomous urban driving*, Autonomous Robots **26** (2009), 123–139 (English).
- [PV07] K. Panta and B.-N. Vo, *Convolution kernels based sequential monte carlo approximation of the probability hypothesis density (PHD) filter*, Information, Decision and Control (IDC), feb. 2007, pp. 336 –341.

-
- [PVS05] K. Panta, B. Vo, and S. Singh, *Improved probability hypothesis density (PHD) filter for multitarget tracking*, Third International Conference on Intelligent Sensing and Information Processing (ICISIP), dec. 2005, pp. 213–218.
- [RB00] S.I. Roumeliotis and G.A. Bekey, *SEGMENTS : a Layered, dual Kalman filter algorithm for indoor feature extraction*, IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), vol. 1, 2000, pp. 454–461.
- [RCV10] B. Ristic, D. Clark, and B.-N. Vo, *Improved SMC implementation of the PHD filter*, 13th Conference on Information Fusion (FUSION), july 2010, pp. 1–8.
- [Rei79] D. Reid, *An algorithm for tracking multiple targets*, IEEE Transactions on Automatic Control **24** (1979), no. 6, 843 – 854.
- [RFBC12] S.A.F. Rodriguez, V. Fremont, P. Bonnifait, and V. Cherfaoui, *An embedded multimodal system for object localization and tracking*, IEEE Intelligent Transportation Systems Magazine **4** (2012), no. 4, 42–53.
- [RVCV11] B. Ristic, B.-N. Vo, D. Clark, and B.-T. Vo, *A metric for performance evaluation of multi-target tracking algorithms*, IEEE Transactions on Signal Processing **59** (2011), no. 7, 3452–3457.
- [SA71] H. W. Sorenson and D. L. Alspach, *Recursive bayesian estimation using gaussian sums*, Automatica **7** (1971), no. 4, 465–479.
- [SBFC01] D. Schulz, W. Burgard, D. Fox, and A.B. Cremers, *Tracking multiple moving targets with a mobile robot using particle filters and statistical data association*, IEEE International Conference on Robotics and Automation (ICRA), vol. 2, 2001, pp. 1665 – 1670.
- [SC12a] S. Solyom and E. Coelingh, *Performance limitations in vehicle platoon control*, 15th IEEE Intelligent Transportation Systems Conference, september 2012.
- [SC12b] A. Swain and D. Clark, *The PHD filter for extended target tracking with estimable extent shape parameters of varying size*, 15th International Conference on Information Fusion (FUSION), july 2012, pp. 1111 –1118.
- [SDG⁺08] I. Smal, K. Draegestein, N. Galjart, W. Niessen, and E. Meijering, *Particle filtering for multiple object tracking in dynamic fluorescence microscopy images : Application to microtubule growth analysis*, IEEE Transactions on Medical Imaging **27** (2008), no. 6, 789 –804.
- [SdOCY11] J. Scharcanski, A.B. de Oliveira, P.G. Cavalcanti, and Y. Yari, *A particle-filtering approach for vehicular tracking adaptive to occlusions*, IEEE Transactions on Vehicular Technology **60** (2011), no. 2, 381–389.
- [SFD02] D. Streller, K. Furstenberg, and K. Dietmayer, *Vehicle and object models for robust tracking in traffic scenes using laser range images*, IEEE 5th International Conference on Intelligent Transportation Systems, 2002, pp. 118 – 123.

- [SFS⁺03] S. Santos, J.E. Faria, F. Soares, R. Araujo, and U. Nunes, *Tracking of multi-obstacles with laser range data for autonomous vehicles*, 3rd National Festival of Robotics Scientific Meeting (ROBOTICA), 2003, pp. 59–65.
- [SGM⁺12] M. Schikora, A. Gning, L. Mihaylova, D. Cremers, and W. Koch, *Box-particle PHD filter for multi-target tracking*, 15th International Conference on Information Fusion (FUSION), 2012, pp. 106–113.
- [SK08] B. Siciliano and O. Khatib, *Springer handbook of robotics*, Gale virtual reference library, Springer, 2008.
- [SKD⁺12] P. Steinemann, J. Klappstein, J. Dickmann, H. Wunsche, and F.V. Hundelshausen, *3D outline contours of vehicles in 3D-lidar-measurements for tracking extended targets*, IEEE Intelligent Vehicles Symposium (IV), june 2012, pp. 432–437.
- [SKK⁺97] A. Siadat, A. Kaske, S. Klausmann, M. Dufaut, and R. Husson, *An optimized segmentation method for a 2D laser-scanner applied to mobile robot navigation*, 3rd symposium on Intelligent Components and Instruments for Control Applications (IFAC), 1997.
- [Skr95] P. Skrzypczynski, *Building geometrical map of environment using IR range finder data*, ch. 2, pp. 403–409, U. Rembold and R. Dillmann and L.O. Hertzberger and T. Kanade, 1995.
- [SLK11] Christoph Stiller, Fernando Puente Leòn, and Marco Kruse, *Information fusion for automotive applications - an overview*, Information Fusion **12** (2011), no. 4, 244 – 252.
- [SSGW11] L. Svensson, D. Svensson, M. Guerriero, and P. Willett, *Set JPDA filter for multitarget tracking*, IEEE Transactions on Signal Processing **59** (2011), no. 10, 4677–4691.
- [Sug99] N. Sugimoto, *Continuous lidar observations of aerosols and clouds in Tsukuba, Japan and Jakarta, Indonesia*, The Pacific Rim Conference on Lasers and Electro-Optics (CLEO), vol. 1, 1999, pp. 29–30.
- [SVV08] D. Schuhmacher, B.-T. Vo, and B.-N. Vo, *A consistent metric for performance evaluation of multi-object filters*, IEEE Transactions on Signal Processing **56** (2008), no. 8, 3447–3457.
- [SW03] H. Sidenbladh and S.-L. Wirkander, *Tracking random sets of vehicles in terrain*, Conference on Computer Vision and Pattern Recognition Workshop (CVPRW), vol. 9, june 2003, p. 98.
- [TCD⁺06] C. Tessier, C. Cariou, C. Debain, F. Chausse, R. Chapuis, and C. Rousset, *A real-time, multi-sensor architecture for fusion of delayed observations : application to vehicle localization*, IEEE Intelligent Transportation Systems Conference (ITSC), 2006, pp. 1316–1321.

-
- [TFBD01] S. Thrun, D. Fox, W. Burgard, and F. Dellaert, *Robust Monte Carlo localization for mobile robots*, *Artificial Intelligence* **128** (2001), 99 – 141.
- [TL09] M. Thuy and F.P. Leon, *Non-linear, shape independent object tracking based on 2D lidar data*, *IEEE Intelligent Vehicles Symposium*, june 2009, pp. 532 –537.
- [TLCZ11] F. Tan, L. Li, B. Cai, and D. Zhang, *Shape template based side-view car detection algorithm*, *3rd International Workshop on Intelligent Systems and Applications (ISA)*, may 2011, pp. 1 –4.
- [VAA07] T.-D. Vu, O. Aycard, and N. Appenrodt, *Online localization and mapping with moving object tracking in dynamic outdoor environments*, *IEEE Intelligent Vehicles Symposium*, june 2007, pp. 190 –195.
- [VADG02] J. Vermaak, C. Andrieu, A. Doucet, and S.J. Godsill, *Particle methods for Bayesian modeling and enhancement of speech signals*, *IEEE Transactions on Speech and Audio Processing* **10** (2002), no. 3, 173 –185.
- [VGP05] J. Vermaak, S.J. Godsill, and P. Pérez, *Monte carlo filtering for multi-target tracking and data association*, *IEEE Transactions on Aerospace and Electronic Systems* **41** (2005), 309–332.
- [VM05] B.-N. Vo and W.-K. Ma, *A closed-form solution for the probability hypothesis density filter*, *8th International Conference on Information Fusion*, vol. 2, july 2005.
- [VR04] A.C. Victorino and P. Rives, *Bayesian segmentation of laser range scan for indoor navigation*, *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, vol. 3, 2004, pp. 2731 – 2736.
- [VSD03] B.-N. Vo, S. Singh, and A. Doucet, *Sequential Monte Carlo implementation of the PHD filter for multi-target tracking*, *Proceedings of the Sixth International Conference of Information Fusion*, vol. 2, 2003, pp. 792–799.
- [VSD05] B.-N. Vo, S. Singh, and A. Doucet, *Sequential Monte Carlo methods for multitarget filtering with random finite sets*, *IEEE Transactions on Aerospace and Electronic Systems* **41** (2005), no. 4, 1224–1245.
- [VVC07] B.-T. Vo, B.-N. Vo, and A. Cantoni, *Analytic implementations of the Cardinalized Probability Hypothesis Density filter*, *IEEE Transactions on Signal Processing* **55** (2007), no. 7, 3553–3567.
- [VWN12] E. Vanpoeringhe, M. Wahl, and J.-C. Noyer, *Model-based detection and tracking of vehicle using a scanning laser rangefinder : A particle filtering approach*, *IEEE Intelligent Vehicles Symposium (IV)*, 2012, pp. 1144–1149.
- [WF01] V. Willhoeft and K. Fuerstenberg, *Multilevel-extension for laserscanners*, *IEEE Intelligent Transportation Systems, 2001. Proceedings, 2001*, pp. 446 –450.
- [Wil00] V. Willhoeft, *Laser scanners for automotive applications in the AF project*, *7th World Congress on Intelligent Systems*, 2000.

- [Woo09] Trevor Wood, *Tracking in dense clutter with the PHD filter*, Proc. IMA Mathematics in Defence, 2009.
- [WSGM99] H. Weisser, P.J. Schulenberg, H. Gollinger, and T. Michler, *Autonomous driving on vehicle test tracks : overview, implementation and vehicle diagnosis*, IEEE/IEEJ/JSAI International Conference on Intelligent Transportation Systems, 1999, pp. 62 –67.
- [WSKD05] S. Wender, M. Schoenherr, N. Kaempchen, and K. Dietmayer, *Classification of laserscanner measurements at intersection scenarios with automatic parameter optimization*, IEEE Intelligent Vehicles Symposium, june 2005, pp. 94 – 99.
- [WVdM00] E.A. Wan and R. Van der Merwe, *The unscented Kalman filter for nonlinear estimation*, The IEEE Adaptive Systems for Signal Processing, Communications, and Control Symposium (AS-SPCC), 2000, pp. 153 –158.
- [WZLS11] G. Wang, Y. Zhang, J. Li, and P. Song, *3D road information extraction from LIDAR data fused with aerial-images*, IEEE International Conference on Spatial Data Mining and Geographical Knowledge Services (ICSDM), july 2011, pp. 362 –366.
- [ZATX03] S. Zhang, M. Adams, F. Tang, and L. Xie, *Geometrical feature extraction using 2D range scanner*, 4th International Conference on Control and Automation (ICCA), june 2003, pp. 901 –905.
- [ZCM04] S.K. Zhou, R. Chellappa, and B. Moghaddam, *Visual tracking and recognition using appearance-adaptive models in particle filters*, IEEE Transactions on Image Processing **13** (2004), no. 11, 1491 –1506.
- [Zha10] W. Zhang, *LIDAR-based road and road-edge detection*, IEEE Intelligent Vehicles Symposium (IV), june 2010, pp. 845–848.
- [ZM10] Y. Zhang and L. Men, *Study of the airborne LIDAR data filtering methods*, 18th International Conference on Geoinformatics, june 2010, pp. 1 –5.
- [ZWY⁺12] H. Zhao, C. Wang, W. Yao, F. Davoine, J. Cui, and H. Zha, *Omni-directional detection and tracking of on-road vehicles using multiple horizontal laser scanners*, IEEE Intelligent Vehicles Symposium (IV), june 2012, pp. 57 –62.

Résumé

Dans les systèmes de perception multicapteurs, un point central concerne le suivi d'objets multiples. Dans mes travaux de thèse, le capteur principal est un télémètre laser à balayage qui perçoit des cibles étendues. Le problème de suivi multi-objets se décompose généralement en plusieurs étapes (détection, association et suivi) réalisées de manière séquentielle ou conjointe. Mes travaux ont permis de proposer des alternatives à ces méthodes en adoptant une approche « track-before-detect » sur cibles distribuées qui permet d'éviter la succession des traitements en proposant un cadre global de résolution de ce problème d'estimation.

Dans une première partie, nous proposons une méthode de détection travaillant directement en coordonnées naturelles (polaires) qui exploite les propriétés d'invariance géométrique des objets suivis. Cette solution est ensuite intégrée dans le cadre des approches JPDA et PHD de suivi multicibles résolues grâce aux méthodes de Monte-Carlo séquentielles.

La seconde partie du manuscrit vise à s'affranchir du détecteur pour proposer une méthode dans laquelle le modèle d'objet est directement intégré au processus de suivi. C'est sur ce point clé que les avancées ont été les plus significatives permettant d'aboutir à une méthode conjointe de détection et de suivi. Un processus d'agrégation a été développé afin de permettre une formalisation des données qui évite tout prétraitement sous-optimal. Nous avons finalement proposé un formalisme général pour les systèmes multicapteurs (multilidar, centrale inertielle, GPS).

D'un point de vue applicatif, ces travaux ont été validés dans le domaine du suivi de véhicules pour les systèmes d'aide à la conduite.

Mots-clés: Perception multi-capteurs, suivi multi-cibles, cibles distribuées, détection, méthodes de Monte-Carlo séquentielles, filtrage PHD, systèmes d'assistance à la conduite

Abstract

In multi-sensor perception systems, an active topic concerns the multiple object tracking methods. In this work, the main sensor is a scanning laser rangefinder perceiving extended targets. Tracking methods are generally composed of a three-step scheme (detection, association and tracking) which is jointly or sequentially implemented. This work proposes alternative solutions by considering a track-before-detect approach on extended targets. It avoids the classic procedures by proposing a global framework to solve this estimation problem.

Firstly, we propose a detection method dealing with measurements in natural coordinates (polar) which is founded on geometrical invariance properties of the tracked objects. This solution is then integrated in the JPDA and PHD multi-target tracking frameworks solved with the sequential Monte-Carlo methods.

The second part of this thesis aims at avoiding the detection step to propose an approach where the object model is directly embedded in the tracking process. This lets to build a novel joint detection and tracking approach. An aggregation process was developed to construct a measurement modeling avoiding any suboptimal preprocessing. We finally proposed a general framework for multi-sensor systems (multiple lidar, inertial sensor, GPS).

These methods were applied in the area of multiple vehicle tracking for the Advanced Driver Assistance Systems.

Keywords: Multi-sensor perception system, multi-target tracking, distributed targets, detection, sequential Monte-Carlo methods, PHD filtering, Advanced Driver Assistance Systems