



HAL
open science

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre 'réactif-coopératif'

Adda Redouane Ahmed Bacha

► To cite this version:

Adda Redouane Ahmed Bacha. Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre 'réactif-coopératif'. Automatique / Robotique. Université Evry -Val d'Essonne, 2014. Français. NNT: . tel-01357694

HAL Id: tel-01357694

<https://hal.science/tel-01357694>

Submitted on 30 Aug 2016

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.

École Doctorale Science et Ingénierie

Thèse

Présentée publiquement le 01/12/2014 pour l'obtention du titre de :

Docteur de l'Université d'Evry Val d'Essonne

Mention Génie informatique, automatique et traitement du signal

Par

Adda Redouane AHMED BACHA

Sujet de la thèse :

**Localisation multi-hypothèses pour l'aide à la conduite :
conception d'un filtre « réactif-coopératif »**

COMPOSITION DU JURY

Rapporteur:	Roger REYNAUD	Professeur, Université Paris Sud
Rapporteur:	Abdelaziz BENSRAIR	Professeur, INSA de Rouen
Examineur:	Etienne COLLE	Professeur, UEVE
Examineur:	Vincent VIGNERON	MDC, HDR, UEVE
Examineur:	Rachid BELAROUSSI	CR1, IFSTTAR
Encadrant:	Alain LAMBERT	MDC, HDR, Université Paris Sud
Directeur de thèse:	Dominique GRUYER	DR, IFSTTAR

“Je commence par remercier le bon Dieu qui m’a donné l’opportunité d’avoir cette vie et les moyens pour ces accomplissements”

Après cela :

Je remercie toutes les personnes m’ayant guidé et ayant participé à mon accomplissement personnel et professionnel.

Je ne saurais lister toutes les personnes influençant ma vie et ma formation sur cette feuille, alors permettez moi de vous présenter mes excuses ; vous qui vous reconnaissez en lisant ces propos sans toutefois y trouver votre mention.

Je tiens à remercier mes parents pour leur éducation et leur patience exemplaires jusqu’à maintenant, ma famille et ma belle famille pour leur présence et mes amis proches.

Merci à mon directeur de thèse et mon co-directeur et toute l’équipe du laboratoire LIVIC pour leurs conseils et leur présence.

Merci à monsieur E.Monacelli mon responsable de master et monsieur D.Aubert sans lesquels je n’aurais peut être jamais croisé le chemin de mon directeur de thèse Dr D.Gruyer. Merci à monsieur S.Mamar qui a été la clé à mon inscription doctorale au départ.

Merci à ma grande sœur, mon beau frère et la famille Kherroubi pour tout le bien que vous avez pu m’apporter.

Au final, je voue une mention spéciale à ma femme et mon fils qui ont su être patients avec moi dans les moments difficiles et pendant les périodes de stress.

Je voudrai aussi citer les noms de quelques personnes qui m’ont toujours accompagné dans mon périple même si elles étaient absentes pour des raisons de distance, je tiens à les remercier d’avoir été pour moi un recueil émotionnel et sentimental, merci à toi :

Mohamed Samir AHMED BACHA

Meriem Sanaa AHMED BACHA

Aïcha AHMED BACHA “Aïcha AMRANI”

Adouda AHMED BACHA “Khadidja KEBIR”

Mohamed El Mehdi BERNOUSSI

Hafida AHMED BACHA

Table des matières

Table des figures	6
Liste des algorithmes	8
Liste des tableaux	9
Résumé	11
Abstract	14
1 Introduction générale	16
2 Présentation de l'étude	21
2.1 Motivations	21
2.2 Objectifs	22
2.3 Méthodologie	23
2.4 Contributions	23
3 La problématique du positionnement des véhicules routiers	25
3.1 Contexte et littérature	25
3.1.1 Le positionnement relatif	25
3.1.2 Le positionnement absolu	26
3.2 Modélisation cinématique du véhicule	29
3.2.1 Référentiel	29
3.2.2 Le modèle Bicyclette	31
3.2.3 Avantages et inconvénients du modèle Bicyclette	32
3.3 Prise en compte des bruits de mesures	33

4	Fusion multicapteurs pour la localisation de véhicules routiers	35
4.1	Introduction	35
4.2	Le filtre de Kalman Étendu	37
4.2.1	Introduction	37
4.2.2	Le filtre de Kalman Étendu : théorie et implémentation	37
4.2.3	Application de l'EKF à la localisation des véhicules routiers	42
4.2.4	Avantages et limites de l'EKF	43
4.3	Le filtre particulaire	44
4.3.1	Introduction	44
4.3.2	Principe d'une approche multi-hypothèses	45
4.3.3	Le filtre particulaire	45
4.3.4	Application du PF à la localisation des véhicules routiers	52
4.3.5	Avantages et limites du filtre à particules	54
4.3.6	Conclusion	54
5	Localisation hybride réactive-coopérative	55
5.1	Introduction	56
5.2	Position du problème	57
5.3	Objectifs	59
5.4	L'optimisation par Essaim de particules "PSO"	60
5.4.1	Introduction à la PSO	60
5.4.2	Algorithme de base	60
5.4.3	Objectif et principe de la PSO	60
5.4.4	Domaines d'applications	62
5.4.5	Paramétrage et variantes PSO	63
5.4.5.1	Voisinage : Taille et topologie	63
5.4.5.2	Calibrage et choix des paramètres	65
5.4.5.3	Évolution des particules en PSO	66
5.4.5.4	Variantes d'évolution	68
5.4.5.5	Fonction de Fitness et multi-objectivité	68
5.5	PSO pour la localisation des véhicules routiers	68
5.6	Le filtre particulaire à essaim de particules "SPF"	70
5.6.1	Introduction	70
5.6.2	Principe et algorithme	70
5.6.3	Application du SPF à la localisation des véhicules routiers	74
5.6.4	Avantages et inconvénients du filtre SPF	76
5.6.5	Conclusion	77
5.7	Le filtre de Kalman Optimisé à Essaim de Particules "OKPS"	78

5.7.1	Introduction	78
5.7.2	Objectifs	79
5.7.3	Formulation de l'approche	79
5.7.4	L'OKPS : Principe et Algorithme	80
5.7.5	Application de l'OKPS à la localisation des véhicules routiers	86
5.7.6	Avantages et limites de l'OKPS	88
5.7.7	Conclusion	88
6	Protocole de test et de validation des estimateurs	90
6.1	Introduction	90
6.2	Performances d'un estimateur	92
6.2.1	Critères de précision	94
6.2.1.1	L'Erreur Euclidienne "EE"	94
6.2.1.2	Les erreurs axiales	95
6.2.1.3	L'erreur quadratique moyenne "RMSE"	95
6.2.1.4	L'erreur euclidienne moyenne "AEE"	96
6.2.1.5	L'erreur géométrique moyenne "GAE"	96
6.2.2	Consistance et crédibilité d'un estimateur	99
6.2.2.1	Consistance	99
6.2.2.2	Crédibilité	101
6.2.2.3	Le contenu en informations	103
6.2.2.4	Intégrité	105
6.2.2.5	Conclusion	105
6.2.3	La robustesse	106
6.2.3.1	La robustesse en égo-localisation	106
7	Tests et analyses des performances	109
7.1	Introduction	109
7.2	Implémentation	111
7.3	Les scénarios	114
7.4	Analyse et comparaison des performances	115
7.5	Conclusion	139
8	Synthèse et perspectives	140
9	Annexe	145
9.1	Présentation du véhicule instrumenté du LIVIC	145
9.2	Capteurs utilisés	147
9.2.1	GNSS (GPS/GLONASS/GALILEO)	147

9.2.2	INS (Centrale inertielle)	149
9.2.3	L'Odomètre	150
9.2.4	Encodeur de braquage des roues	151
9.3	Calibrage PSO	151
Bibliographie		156

Table des figures

3.1	GPS : Occultation et Multi-trajets dans des canyons urbains	26
3.2	Modélisation en modèle Bicyclette	31
4.1	Égo-localisation par Filtrage de Kalman	42
4.2	Schématisation de la localisation multi-hypothèses	44
5.1	PSO : Principe de déplacement d'une particule	62
5.2	Voisinage géographique	63
5.3	Différentes configurations de voisinage social (de haut en bas et de gauche à droite) : En étoile, en anneau et en cercle.	64
5.4	Exemple de comportements suivant le paramétrage PSO	65
5.5	SPF par hybridation PF/PSO	71
5.6	L'égo-localisation SPF	74
5.7	Algorithme de l'OKPS	81
6.1	Comparaison des critères de précision	98
6.2	Intervalle de consistance construit par une densité de probabilité suivant une distribution χ^2 avec 5 degrés de liberté	102
6.3	Ellipse d'incertitude d'estimation de l'égo-localisation	104
7.1	Diagramme de test des approches d'égo-localisation sous RtMaps	112
7.2	Pistes Satory : Routière et Val d'Or	113
7.3	Erreur Euclidienne pour des données AG132 Synchronisées	117
7.4	Erreur quadratique moyenne pour des données AG132 Synchronisées	118
7.5	Erreur Euclidienne moyenne pour des données AG132 Synchronisées	119
7.6	Erreur géométrique moyenne pour des données AG132 Synchronisées	120
7.7	Erreurs axiales pour le test AG132 Synchronisé	122
7.8	Enveloppes axiales 2σ pour le test AG132 Synchronisé	123
7.9	Erreur Euclidienne pour des données AG132 brutes	125

7.10	Erreur quadratique moyenne pour des données AG132 brutes	126
7.11	Erreur Euclidienne moyenne pour des données AG132 brutes	127
7.12	Erreur géométrique moyenne pour des données AG132 brutes	128
7.13	Erreurs axiales pour le test AG132 brute	130
7.14	Enveloppes axiales 2σ pour le test AG132 Synchronisé	131
7.15	Erreur Euclidienne pour des données AG132 avec des réflexions GPS	132
7.16	Erreur quadratique moyenne pour des données AG132 avec des réflexions GPS	133
7.17	Erreur Euclidienne moyenne pour des données AG132 avec des réflexions GPS	134
7.18	Erreur géométrique moyenne pour des données AG132 avec des réflexions GPS	135
7.19	Erreurs axiales pour le test AG132 avec des réflexions GPS	137
7.20	Enveloppes axiales 2σ pour le test AG132 avec des réflexions GPS . .	138
9.1	Véhicules équipés du LIVIC [Réalisé par Dr D.GRUYER]	146
9.2	Constellation des satellites GPS et principe de triangulation	148
9.3	Encodeur d'angle de braquage	152

Liste des Algorithmes

1	Algorithme du filtre particulaire appliqué à la localisation des véhicules	53
2	PSO : Algorithme de base	61
3	Algorithme du filtre SPF appliqué à la localisation des véhicules	75
4	Algorithme du filtre OKPS appliqué à la localisation des véhicules . . .	87

Liste des tableaux

7.1	Valeurs finales des erreurs moyennes obtenues pour le test AG132 Synchronisé	116
7.2	Erreurs axiales moyennes et écarts types axiaux moyens pour le test AG132 Synchronisé	121
7.3	Valeurs finales des erreurs moyennes obtenues pour le test AG132 brute	125
7.4	Erreurs axiales moyennes et écarts types axiaux moyens pour le test AG132 brute	129
7.5	Valeurs finales des erreurs moyennes obtenues pour le test AG132 avec des réflexions GPS	132
7.6	Erreurs axiales moyennes et écarts types axiaux moyens pour le test AG132 Synchronisé	139
9.1	PSO : Calibrage du nombre de particules N	153
9.2	PSO : Calibrage du facteur d'inertie W	154
9.3	PSO : Calibrage du seuil de rééchantillonnage N_{th}	155

Résumé

“Lorsqu’on utilise des données provenant d’une seule source,
C’est du plagiat ;
Lorsqu’on utilise plusieurs sources,
C’est de la fusion de données”
[Das14]

Ces travaux présentent une approche de fusion de données collaborative innovante pour l'égo-localisation de véhicules routiers. Cette approche appelée filtre de Kalman optimisé à essaim de particules (Optimized Kalman Particle Swarm) est une méthode de fusion de données et de filtrage optimisé. La fusion de données est faite en utilisant les données d'un GPS à faible coût, une centrale inertielle, un compteur odométrique et un codeur d'angle au volant. Ce travail montre que cette approche est à la fois plus robuste et plus appropriée que les méthodes plus classiques d'égo-localisation aux situations de conduite urbaine. Cette constatation apparaît clairement dans le cas de dégradations des signaux capteurs ou des situations à fortes non linéarités. Les méthodes d'égo-localisation de véhicules les plus utilisées sont les approches bayésiennes représentées par le filtre de Kalman étendu (Extended Kalman Filter) et ses variantes (UKF, DD1, DD2). Les méthodes bayésiennes souffrent de sensibilité aux bruits et d'instabilité pour les cas fortement non linéaires. Proposées pour couvrir les limitations des méthodes bayésiennes, les approches multi-hypothèses (à base de particules) sont aussi utilisées pour la localisation égo-véhiculaire. Inspiré des méthodes de simulation de Monte-Carlo, les performances du filtre à particules (Particle Filter) sont fortement dépendantes des ressources en matière de calcul. Tirant avantage des techniques de localisation existantes et en intégrant les avantages de l'optimisation métaheuristique, l'OKPS est conçu pour faire face aux bruits, aux fortes dynamiques, aux données non linéaires et aux besoins d'exécution en temps réel. Pour l'égo-localisation d'un véhicule, en particulier pour les manœuvres très dynamiques sur route, un filtre doit être robuste et réactif en même temps. Le filtre OKPS est conçu sur un nouvel algorithme de localisation coopérative-réactive et dynamique inspirée par l'Optimisation par Essaim de Particules (Particle Swarm Optimization) qui est une méthode métaheuristique. Cette nouvelle approche combine les avantages de la PSO et des deux autres filtres : Le filtre à particules (PF) et le filtre de Kalman étendu (EKF). L'OKPS est testé en utilisant

des données réelles recueillies à l'aide d'un véhicule équipé de capteurs embarqués. Ses performances sont testées en comparaison avec l'EKF, le PF et le filtre par essaim de particules (Swarm Particle Filter). Le filtre SPF est un filtre à particules hybride intéressant combinant les avantages de la PSO et du filtrage à particules ; Il représente la première étape de la conception de l'OKPS. Les résultats montrent l'efficacité de l'OKPS pour un scénario de conduite à dynamique élevée avec des données GPS endommagés et/ou de qualité faible.

Points-Saillants :

- Localisation robuste pour véhicules à dynamique rapide
- Une nouvelle méthode de fusion de données hybride
- Fusion de données multi-capteurs pour la localisation de véhicules
- Validation et test avec des données réelles

Mots-Clés :

Localisation, robotique mobile, filtre de Kalman, EKF, Optimisation par essaim de particules, PSO, Filtre à particules, fusion de données, égo-localisation véhicule, navigation, GPS.

Abstract

“When we use information from one source,
it’s plagiarism ;
Wen we use information from many,
it’s information fusion”

[Das14]

This work presents an innovative collaborative data fusion approach for ego-vehicle localization. This approach called the Optimized Kalman Particle Swarm (OKPS) is a data fusion and an optimized filtering method. Data fusion is made using data from a low cost GPS, INS, Odometer and a Steering wheel angle encoder. This work proved that this approach is both more appropriate and more efficient for vehicle ego-localization in degraded sensors performance and highly nonlinear situations. The most widely used vehicle localization methods are the Bayesian approaches represented by the EKF and its variants (UKF, DD1, DD2). The Bayesian methods suffer from sensitivity to noises and instability for the highly non-linear cases. Proposed for covering the Bayesian methods limitations, the Multi-hypothesis (particle based) approaches are used for ego-vehicle localization. Inspired from monte-carlo simulation methods, the Particle Filter (PF) performances are strongly dependent on computational resources. Taking advantages of existing localization techniques and integrating metaheuristic optimization benefits, the OKPS is designed to deal with vehicles high nonlinear dynamic, data noises and real time requirement. For ego-vehicle localization, especially for highly dynamic on-road maneuvers, a filter needs to be robust and reactive at the same time. The OKPS filter is a new cooperative-reactive localization algorithm inspired by dynamic Particle Swarm Optimization (PSO) metaheuristic methods. It combines advantages of the PSO and two other filters : The Particle Filter (PF) and the Extended Kalman filter (EKF). The OKPS is tested using real data collected using a vehicle equipped with embedded sensors. Its performances are tested in comparison with the EKF, the PF and the Swarm Particle Filter (SPF). The SPF is an interesting particle based hybrid filter combining PSO and particle filtering advantages ; It represents the first step of the OKPS development. The results show the efficiency of the OKPS for a high dynamic driving scenario with damaged and low quality GPS data.

Highlights :

- Robust high dynamic localization for vehicles
- A new hybrid data fusion method
- Low cost GPS, INS/Odometer data fusion for vehicle localization
- Validation an test with real word data

Localisation multi-hypothèses pour l’aide à la conduite : conception d’un filtre "réactif-coopératif"

Keywords :

Localization, mobile robotic, Kalman filter, EKF, Particle Swarm Optimization, PSO, Particle filter, data fusion, vehicle positioning, navigation, GPS.

Chapitre 1

Introduction générale

L'aide à la conduite est une branche en plein essor et qui vise à développer des systèmes d'interaction entre le conducteur, le véhicule et l'environnement qui les entoure. Les applications et dispositifs d'aide à la conduite contribuent à l'amélioration du confort et de la sécurité. La conduite devient alors plus intuitive et moins complexe à l'aide de moyens permettant de simplifier l'interaction entre le conducteur et le véhicule et en fournissant une meilleure perception de l'environnement. Dans l'aide à la conduite, deux principaux types de systèmes peuvent être distingués : Les systèmes actifs et les systèmes passifs. Les systèmes actifs (actionneurs) sont des systèmes agissant sur le comportement du véhicule en provoquant des actions indépendantes des consignes des intentions du conducteur. Ces systèmes sont mis en œuvre afin de pallier les limites et les défaillances de réactivité humaine par exemple en déclenchant des freinages d'urgence. Les systèmes passifs quant à eux ne provoquent aucune action de manière directe. Ces systèmes se contentent de fournir l'information au conducteur ou à un autre système décisionnel. Ces systèmes sont souvent des dispositifs de perception qui permettent d'avoir une donnée cachée en temps normal ou de fournir une donnée utile pour la conduite. Un système de perception doit être fiable et précis afin de garantir la véracité des informations fournies. Le coût d'un tel système est aussi un critère décisif dans son avenir industriel.

La localisation est une brique technologique clé pour n'importe quel système d'assistance à la conduite (ADAS¹). L'information de localisation peut être utilisée pour développer de nouveaux services qui visent à accroître l'autonomie et la sécurité des conducteurs. Ces nouveaux services ouvriront à leur tour la voie à d'autres systèmes de transports intelligents dédiés aux applications de la route (ITS-R²) comme par

1. ADAS : Advanced Driving Assistance System

2. ITS-R : Intelligent Transport Systems applied to Road applications

exemple : les services de voiturier automatisé ainsi que les véhicules à conduite autonome. Ce qui fait de l'égo-localisation précise des véhicules un enjeu important dans le domaine de la recherche en systèmes de transports intelligents (ITS³). L'objectif d'un grand nombre de travaux de recherche en localisation est de fournir un positionnement plus précis et plus robuste que celui obtenu avec un système classique de navigation globale par satellite (GNSS⁴). Le problème de cet objectif, en plus d'obtenir la précision requise est de fournir une solution de positionnement précise, fiable et consistante avec le moins de coût financiers possible. Ainsi, les capteurs déjà embarqués ou des capteurs à faible coût sont utilisés en complément du GPS afin d'effectuer une fusion de données. Des capteurs supplémentaires comme la centrale inertielle (INS⁵), l'odomètre, et le capteur de braquage du volant peuvent être utilisés pour apporter de nouvelles informations. Outre les avantages en termes de précision, robustesse et fiabilité, l'intérêt de la fusion du GPS avec des capteurs proprioceptifs est que cette fusion de données permette une meilleure estimation de l'égo-localisation du véhicule à une fréquence plus élevée qu'avec un simple GPS. En plus de la localisation à une fréquence temps réel, les capteurs proprioceptifs permettent de continuer à fournir une égo-localisation pendant une coupure du signal GPS, rendant par conséquent le processus de localisation robuste aux masquages GPS et aux dégradations du signal. En complément final à la donnée de localisation, les incertitudes respectives des données GPS et proprioceptives peuvent être aussi fusionnées afin de fournir une information sur la confiance attribuée à ce positionnement. Ceci s'avère très utile dans les cas de perturbations GPS causées par des canyons urbains.

Il existe un grand nombre de travaux de recherche se concentrant sur la fusion de données pour les applications dédiées à la localisation de véhicules [ANL03, ABGL13, LBCT03, SLM05, NGG07, TMZIUMGS07, ZIBPJ08]. La localisation en Robotique Mobile est un problème d'estimation de l'emplacement du robot (véhicule) en position et orientation par rapport à son environnement. L'information issue de la localisation précise représente un élément important dans la conception d'un véhicule autonome ou d'un système d'aide à la conduite. D'un point de vue probabiliste, le problème de la localisation est un processus d'estimation d'état du véhicule [May82, Lew86, BS92, BSL93]. L'estimation d'état est généralement traitée en utilisant des méthodes de Markov en raison de leur gestion logique et simple des états. Le filtre de Kalman (KF⁶) est le filtre optimal pour l'estimation d'état dans le cas des

3. ITS : Intelligent Transport Systems

4. GNSS : Global Navigation Satellite Systems

5. INS : Inertial Navigation System

6. KF : Kalman Filter

systèmes linéaires gaussiens [Kal60]. Les modélisations cinématiques précises pour un véhicule sont pour la plupart sous forme de modèles non linéaires. Les chercheurs ont donc opté pour une adaptation du KF afin qu'il soit compatible à l'estimation d'état non linéaire. Afin de faire face à cette non linéarité, le Filtre de Kalman Étendu (EKF ⁷) et d'autres variantes non linéaires du KF (UKF ⁸, DD1 ⁹, DD2 ¹⁰) ont été proposés [JU97, IX00, JU96, Jul97]. Ainsi, la majorité des approches appliquées à la fusion de données pour le positionnement des véhicules routiers sont des variantes non linéaires du KF [NNLGG09, LBDS04, MGLG05, AUBM10, KFI08]. Après la démocratisation de ces approches, une nouvelle approche multi-hypothèses à base de particules a été développée pour pallier les limites de stabilité des versions non linéaires du KF tel que l'EKF. Le filtre à particules ou filtre particulaire (PF ¹¹) a ensuite commencé à être employé dans la recherche sur les applications d'égo-localisation des véhicules autonomes ainsi que pour le tracking (suivi) [HNT10, GGLV12, BBM09]. Cependant, il a été noté que le PF basique souffre de dégénérescence des particules et que sa précision dépend du nombre de particules [SAC02]. Plus le nombre de particules est important plus le PF est précis, mais l'augmentation du nombre de particules a un impact direct sur le temps de calcul. Pour éviter la dispersion des particules et la divergence du PF, des approches d'échantillonnage et de rééchantillonnage sont développées et adoptées [BDH00, DC05, Hol04]. Le rééchantillonnage consiste en une réorganisation de la distribution des particules en éliminant les particules inconsistantes et en dupliquant celles qui sont efficaces en fonction de leurs poids. Une comparaison pertinente des approches les plus connues en rééchantillonnage est disponible dans [HSG06]. Le PF à rééchantillonnage permet d'éviter l'explosion de l'essaim par dégénérescence des particules mais ses performances restent tout autant dépendantes du nombre de particules utilisées. Visant à créer des approches d'égo-localisation intelligentes pour des véhicules autonomes intelligents, la communauté scientifique s'est orientée vers les approches hybrides fusionnant les avantages de méthodes existantes.

Préalablement destiné à simuler le comportement d'animaux en groupe, attribuée à Eberhart, Shi et Kennedy [SE98a], L'optimisation par Essaim de Particules (OEP ou PSO ¹² en anglais) est une méthode d'optimisation métaheuristique améliorée pour traiter les problèmes d'optimisation de manière itérative [Cle03, BVA07,

7. EKF : Extended Kalman Filter

8. UKF : Unscented Kalman Filter

9. DD1 : Divided Difference of First Order

10. DD2 : Divided Difference Second Order

11. PF : Particle Filter

12. PSO : Particle Swarm Optimization

EC03, RSC06, CCL02]. En PSO, les particules (agents) sont équipés avec des capacités cognitives leur donnant la possibilité d'adopter des comportements sociaux au sein d'une communauté formée par l'ensemble des particules, cette communauté de particules interactives est appelée *essaim*. Les particules de la PSO sont en mesure d'échanger des informations et de coopérer mutuellement de façon à atteindre un objectif représentant la meilleure solution au problème traité. Ces particules se déplacent individuellement à travers l'espace de recherche vers la région où la probabilité de l'objectif (positionnement) est la plus élevée. Les particules évoluent aussi en optimisant leurs estimations, elles se déplacent vers les meilleures performances de leurs voisins (communication sociale). De manière itérative, les particules convergent vers les optima locaux ou vers l'optimum global.

Ces dernières années, les méthodes de localisation hybrides inspirées de la PSO ont fait l'objet d'un engouement dans la recherche appliquée aux applications d'égo-localisation et de navigation [GGLV12, HNT10, JC09]. Le filtre particulaire à essaim de particules (SPF¹³) est une hybridation du PF à rééchantillonnage avec la PSO [HNT10, ZPP11a, TFX06, ZPP11b, FTX07]. La PSO est utilisée pour optimiser la distribution des particules permettant par conséquent de pallier les limitations du PF en minimisant la dépendance des performances au nombre de particules et en minimisant le besoin en rééchantillonnage évitant ainsi la dispersion des particules. Intégrer la PSO au PF permet aussi d'avoir une méthode d'adaptation de la PSO qui est une technique d'optimisation afin qu'elle puisse être employée pour des applications d'égo-localisation et de suivi [CBWC12]. La PSO est aussi utilisée pour des applications d'égo-localisation en milieu intérieur de robots mobiles à l'aide de balises [HNT10]. Toutefois, pour la localisation de véhicules à dynamique rapide sur la base d'une fusion de données multi-capteurs, la technique du dernier article cité montre des problèmes de paramétrage et de convergence prématurée. La PSO dans [JC09] est utilisée en tant que composant complémentaire au filtre de Kalman servant à la calibration des paramètres de bruits. Ce processus permet au filtre de Kalman de mieux gérer les cas limites de fortes non-linéarités (brusque changement de dynamique) pour la localisation en aéronautique. Le résultat obtenu est un processus basé sur un EKF aidé par la PSO consommant trop de temps de calcul et nécessitant le réglage expérimental de nombreux paramètres de la PSO.

Inspirés par la localisation hybride des travaux de recherche cités auparavant, les travaux suivants présentent une méthode de localisation hybride innovante conjuguant les avantages de plusieurs approches à la fois. Le filtre de Kalman Optimisé à Essaim de Particules (OKPS¹⁴) est une approche de fusion de données appliquée à la

13. SPF : Swarm Particle Filter

14. OKPS : Optimized Kalman Particle Swarm

localisation de véhicules routiers à dynamique rapide. L'OKPS considère le problème d'égo-localisation véhiculaire comme un problème de positionnement probabiliste en temps réel en introduisant une gestion de la distribution des particules, traitée comme un problème d'optimisation dynamique. A chaque pas de temps, l'OKPS tente de trouver la meilleure position du véhicule en fonction des éléments suivants : l'état précédent du véhicule, les mesures actuelles des capteurs et les informations échangées entre les particules voisines. L'OKPS minimise les besoins de paramétrage par rapport à une méthode PSO classique et permet de conserver les avantages des approches sur lesquelles se base l'hybridation PSO/EKF/PF.

L'OKPS sera testé et comparé dans le cadre d'une application d'égo-localisation de véhicules routiers en conduite urbaine par rapport à d'autres approches largement employées dans ce domaine telles que l'EKF et le PF. Ces approches seront classées en terme de précision et de robustesse suivant les performances affichées lors de tests expérimentaux effectués avec des jeux de données réelles collectées avec un véhicule équipé de capteurs lors de scénarios de conduite sur les pistes de Satoty. Les performances en précision des filtres en localisation seront évaluées par rapport à une référence fournie par un GPS RTK¹⁵ centimétrique. La robustesse et la consistance des filtres seront évalués en analysant les résultats fournis par les filtres et les incertitudes associées à ces résultats suivant des critères conçus pour et dédiés à l'égo-localisation des véhicules. Les résultats obtenus dans ces travaux donnent une distinction significative entre les performances des différentes approches. La comparaison est faite en termes de précision et sensibilité/robustesse aux valeurs aberrantes. L'OKPS se distingue des autres méthodes en fonction des situations et des conditions du signal GPS. Cette distinction est plus significative pour des cas de perturbations et réflexions GPS dans les milieux urbains (réflexions qui provoquent des multi-trajets : problème des canyons urbains).

15. RTK : Real Time Kinematic

Chapitre 2

Présentation de l'étude

Sommaire

2.1	Motivations	21
2.2	Objectifs	22
2.3	Méthodologie	23
2.4	Contributions	23

2.1 Motivations

Cette thèse s'inscrit dans la suite des travaux effectués au LIVIC (Laboratoire sur les Interactions Véhicules-Infrastructure-Conducteurs) qui travaille sur plusieurs projets français et internationaux (CooPerCom, eFuture, Haveit, SCOREF, CVIS, SafeSpot) ayant pour finalité le développement de systèmes avancés pour l'aide à la conduite urbaine. Chaque système intégré à un véhicule, qu'il soit actif (aide au freinage d'urgence, anti-dérapiage, etc.) ou passif (guidage, indicateur de présence en angle mort, radar de recul) nécessite des informations précises et fiables obtenues à l'aide de capteurs. La localisation, qui représente l'information en position et en orientation d'un égo-véhicule est une donnée couramment utilisée par les automobilistes. La disponibilité de cette donnée fournit une source d'informations qui alimente plusieurs applications et services tels que le guidage et la planification de trajectoire. La localisation dans le cas général est assurée par des systèmes à base de systèmes satellitaires GNSS (Global Navigation Satellite System) aidé par des balises au sol pour gagner en précision. Ce type de source d'information, qui est suffisant pour un guidage urbain et extra urbain, reste cependant vulnérable et n'est pas toujours très fiable. La précision d'un GPS bas cout est de l'ordre de 5 à 6 mètres

autour de la position indiquée, cette précision n'est pas suffisante pour servir d'information à des systèmes actifs tels que la délégation de conduite. Cette thèse traite cette problématique de précision et fiabilité en essayant de tirer profit des capteurs existants et embarqués dans un véhicule. Le but de ce travail de recherche est de faire collaborer plusieurs capteurs, chacun palliant les défauts de l'autre dans le but d'assurer une localisation robuste et précise en même temps. Dans un contexte de réalité économique, les capteurs envisagés dans cette étude sont des capteurs présents ou qui seront facilement présents dans les véhicules de série dans les années à venir. Le travail de recherche est quand à lui axé sur les méthodes mathématiques appliquées aux différents signaux (données) envoyés par ces multiples capteurs afin d'assurer une collaboration entre ces différentes sources dans le but de générer une information globale de localisation précise et robuste, d'où le titre : « Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif" », La partie du titre mentionnant le multi-hypothèses est en rapport avec l'idée de base de l'approche développée, ce qui sera expliqué dans le corps de la thèse.

2.2 Objectifs

Le but se résume par l'obtention en sortie du système d'une localisation précise et robuste. Cette information est une « brique » technologique essentielle pour les systèmes d'assistance à la conduite, notamment pour les systèmes actifs agissant sur la trajectoire des véhicules. Robustesse et précision peuvent être obtenues en combinant les informations délivrées par plusieurs capteurs grâce à des techniques de « fusion hybride ». Techniquement l'objectif est de concevoir une nouvelle approche de localisation robuste, fiable, adaptée aux situations complexes et aux manœuvres rapides d'un véhicule routier. La finalité est un filtre « réactif-coopératif » utilisant plusieurs sources de données (capteurs), un modèle d'évolution ainsi qu'une répartition particulière basée sur ce modèle. Afin de prendre en compte l'adéquation de chaque particule à la situation courante, un mécanisme de type attraction/répulsion (approche par essaim) sera utilisé et intégré au filtre. Les applications visées par ces travaux sont très liées au développement de l'orientation « Route Automatisée » prise actuellement par l'IFSTTAR. Plus précisément, les sorties de cette nouvelle approche pourront être utilisées dans les nouvelles applications coopératives en développement (projets CooPerCom) pour assurer et garantir une robustesse et une forte fiabilité de la perception de l'état d'un véhicule.

2.3 Méthodologie

La localisation précise et robuste est une « brique » technologique essentielle pour les systèmes d'assistance à la conduite, notamment pour les systèmes actifs agissant sur la trajectoire des véhicules. Robustesse et précision peuvent être obtenues en combinant les informations délivrées par plusieurs capteurs grâce à des techniques de « fusion hybride ». La fusion multicapteurs se traduit par l'utilisation des techniques permettant le traitement des signaux délivrés par différents capteurs afin d'améliorer l'information globale sur l'état estimé du véhicule. Le filtrage récursif se compose d'une étape de prédiction fondée sur un modèle d'évolution faisant intervenir les capteurs proprioceptifs. Ensuite une étape de correction utilisant les données du GPS permet de corriger la prédiction afin d'obtenir une estimation de la position. Cette technique, bien adaptée à la robotique mobile à dynamique lente ne permet cependant pas d'obtenir le niveau de performances requis pour des mobiles à dynamique rapide. Dans cette thèse nous proposons donc de concevoir une nouvelle approche de localisation robuste, fiable, adaptée aux situations complexes et aux manœuvres rapides d'un véhicule routier. Cette approche utilisera et complètera les connaissances déjà acquises par le LIVIC sur les approches de localisation multi-modèles [NGG07, NGGL11], sur le débruitage des données issues de capteurs proprioceptifs [NN09] et sur les techniques d'auto-diagnostic en temps réel d'un système de localisation [Mou06]. Le filtre « réactif-coopératif » basé sur le fonctionnement d'un ensemble d'échantillons évoluant et échangeant des informations sera validé expérimentalement. Cette validation se fera à l'aide de données réelles collectées lors de scénarios enregistrés par les véhicules instrumentés du LIVIC. Finalement un protocole de test et d'évaluation sera proposé permettant de tester et valider les performances de la nouvelle approche comparativement aux autres méthodes. Les critères utilisés devront être assez génériques afin de permettre la comparaison de différentes approches tout en permettant de caractériser et de classer les performances. Ces critères seront des indicateurs d'erreur, de variance et de consistance du filtre, par rapport à une référence.

2.4 Contributions

Cette thèse propose une nouvelle approche de fusion de données pour la localisation. Cette approche fusionne les données issues de capteurs embarqués dans un véhicule afin de faire une égo-localisation précise et robuste du véhicule. L'approche proposée est nommée "OKPS" signifiant en français Le filtre de Kalman Optimisé à Essaim de Particules. L'OKPS est le fruit d'une hybridation des principes théo-

riques des approches PSO, PF et EKF. Le résultat est une conception algorithmique hybride fusionnant plusieurs briques théoriques issues des approches citées. Cette conception a pour but de conserver les avantages de chaque approche et d'en réduire les inconvénients.

L'OKPS est comme le PF, basé sur un ensemble de particules et chacune de ces particules représente une hypothèse de localisation. Les particules sont différentes de celles d'un simple PF car elles sont dotées des attributs des particules d'optimisation PSO. Il en ressort des particules communicantes entre elles et qui évoluent suivant les influences du groupe de particules en échangeant des informations. Les informations échangées sont des vecteurs de positionnements et leurs vraisemblances ou des mesures de confiance associées à ces vecteurs. Ces mesures de confiance sont calculées à l'aide d'un mécanisme d'auto-diagnostic qui permet à chaque particule de juger indépendamment des autres sa performance et de transmettre ce jugement. Ce principe d'auto-diagnostic applique le principe théorique de la matrice de vraisemblance de l'EKF. Enfin, une fois les étapes de communication et d'évolution achevées, le filtre fournit une seule position probable du véhicule en lui associant une mesure de confiance avec une autre matrice de variance covariance représentant la distribution de l'essaim autour de cet état. Cette fusion qui permet de donner une sortie traduisant l'état global de l'essaim est faite grâce à une fonction de pondération appelée *fonction de Fitness*. La fonction de fitness est basée sur la fonction de pondération probabiliste du filtrage particulaire pour la localisation des véhicules (voir les équations 4.14 et 4.15 page 49) . Cependant, cette nouvelle fonction est aussi adaptative et intègre la notion d'auto-diagnostic des particules, permettant de faire un compromis entre les données capteurs et l'optimisation par essaim de particules intégrant un côté aléatoire et représentant l'inertie des particules. Ces différentes briques innovantes, constituent l'ensemble de l'algorithme de l'OKPS qui représente un nouveau type de filtrage hybride "réactif-coopératif" dans le domaine de la fusion de données multi-sources appliqué au domaine de la localisation automobile.

Chapitre 3

La problématique du positionnement des véhicules routiers

Sommaire

3.1	Contexte et littérature	25
3.1.1	Le positionnement relatif	25
3.1.2	Le positionnement absolu	26
3.2	Modélisation cinématique du véhicule	29
3.2.1	Référentiel	29
3.2.2	Le modèle Bicyclette	31
3.2.3	Avantages et inconvénients du modèle Bicyclette	32
3.3	Prise en compte des bruits de mesures	33

3.1 Contexte et littérature

La localisation de véhicule routier peut être partagée en trois types de localisations : la localisation relative, la localisation absolue et la localisation qui fusionne ces deux localisations précédentes et qui représente donc la localisation hybride.

3.1.1 Le positionnement relatif

Ce type de localisation est dit relatif car il ne fournit que l'état de l'égo-véhicule toujours par rapport à un référentiel lié au véhicule (un point de départ connu). Le

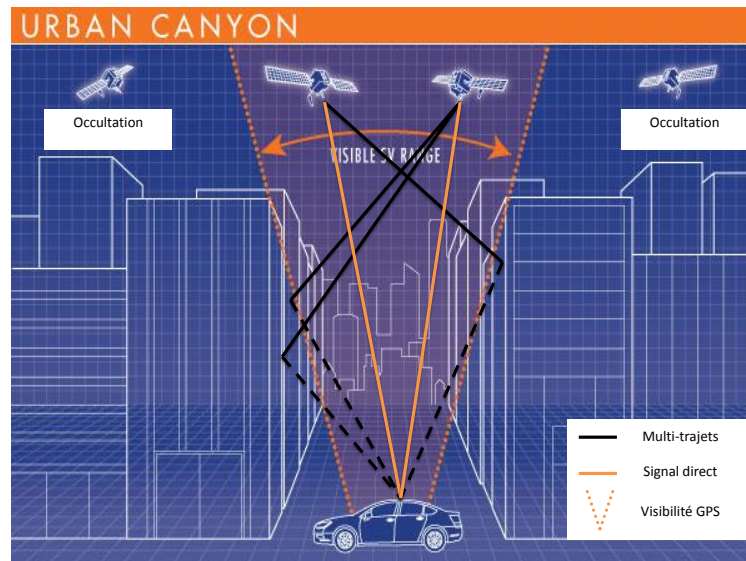


FIGURE 3.1 – GPS : Occultation et Multi-trajets dans des canyons urbains

positionnement relatif peut être aussi composé de trois sous types de positionnement relatifs qui sont le positionnement odométrique, le positionnement inertiel et l'hybride qui combine les deux. Ces sous types de positionnement correspondent au capteur utilisé afin de produire le positionnement relatif. Le déplacement du véhicule est déterminé par intégration successive d'informations décrivant la cinématique du véhicule. En partant du point de départ, la position du véhicule est donc successivement calculée à l'aide des informations des capteurs proprioceptifs et du modèle d'évolution de notre véhicule. Les capteurs proprioceptifs les plus utilisés pour la localisation relative ainsi que le modèle d'évolution du véhicule employé seront présentés par la suite.

3.1.2 Le positionnement absolu

Une localisation est dite absolue quand elle permet d'exprimer directement le positionnement du véhicule dans un référentiel global donné (extérieur au véhicule) sans pour autant se rattacher à une initialisation connue de la position ou à une incrémentation successive de mouvements à partir d'un point de départ. Deux types d'approches peuvent être citées pour le positionnement absolu. Le premier utilise des balises ou repères actifs qui transmettent des informations au véhicule par le moyen de communication sans fil. Grâce à ces informations reçues, le système de perception

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

construit par trilatération¹ la position absolue du véhicule. Cette méthode constitue le principe employé par le positionnement GPS ou par GSM. Le deuxième type se base sur l'utilisation d'éléments reconnaissables dans l'environnement (amers) mais non actifs tels que des points de repères ou des balises dont les positions sont connues dans un environnement connu. Cette dernière stratégie se base sur des capteurs télémétriques (Laser, Radar, Lidar) ou sur des systèmes de visions (caméra : mono, stéréo, ou omnidirectionnelle). Le processus de localisation dans ce cas là se fait suivant trois étapes : La première est la construction d'une carte de perception locale de l'environnement de l'égo-véhicule à l'aide des informations recueillies par le capteur (détection et reconnaissance de point d'intérêts). La deuxième étape est la mise en correspondance de cette carte locale avec une carte globale de l'environnement qui constitue actuellement un référentiel. La troisième et dernière étape consiste à calculer la position absolue et l'orientation du véhicule par triangulation des informations des capteurs extéroceptifs. La carte globale décrivant l'environnement entourant le véhicule peut aussi ne pas être disponible, dans ce cas, le système de perception peut construire sa propre carte de perception globale au fur et à mesure de son exploration de l'environnement. Cette technique s'intitule le SLAM² [BDW06]. La présentation du principe détaillé de la localisation absolue par système satellitaire et les différents référentiels qui peuvent être employés seront présentés par la suite.

Il existe un cas où les systèmes de vision peuvent être utilisés pour faire de la localisation relative. Ceci est appelé l'Odométrie-Visuelle. L'odométrie visuelle utilise la caméra pour calculer progressivement le mouvement d'un robot entre deux ou plusieurs images consécutives et le positionner dans les six degrés de liberté dans un monde 3D. Les approches d'odométrie visuelle destinées à des applications de localisation des véhicules routiers doivent répondre à des contraintes de coût et de fonctionnement en temps réel tout en permettant l'utilisation de modèles d'évolution simplifiés. En raison de travaux précédents effectués au sein du laboratoire IFSTTAR/LIVIC sur les méthodes basées sur des caméras Stéréo ou Monoculaires, nous excluons dans notre synthèse les méthodes basées sur les caméras Omnidirectionnelles.

La plupart des approches existantes pour l'odométrie visuelle sont basées sur les étapes suivantes :

- Acquisition d'images : En utilisant soit une caméra 'monoculaire', une paire de caméras 'stéréo' ou même deux paires stéréo, ou une caméra omnidirectionnelle.
- Correction de l'image : appliquer les techniques de traitement d'images pour

1. Trilatération : calcul de la position par géométrie uniquement à l'aide des distances, contrairement à la triangulation qui utilise les angles et les distances

2. Simultaneous Localization And Mapping

la correction de distorsion d'objectif, rectification épipolaire pour le cas de la stéréo... etc.

- La détection de points d'intérêts ou de zones caractéristiques : se divise en deux catégories bien distinctes, denses et éparses. La détection se fait par différentes méthodes tel que : SIFT, SURF, HARRIS... etc. [NNB04, FS12].

- l'appariement de points d'intérêts : La mise en correspondance des points d'intérêts entre images, gauche et droite pour la stéréo, ou bien images séparées par intervalle temporel pour des méthodes de flot optique.

- Élimination des valeurs aberrantes : généralement par des méthodes stochastiques, par exemple avec le RANSAC [CGDM10].

- Estimation du mouvement : Soit par des techniques basées sur l'apparence et le flot optique (minimisent une erreur directement sur la base des mesures de l'image. elles sont souvent monoculaires et font des hypothèses fortes sur la nature de la structure dans la scène ou le modèle d'appareil photo). Soit par des techniques "directes" basées sur des modèles (minimisent l'erreur du capteur directement dans l'espace et évitent par la suite les fonctions d'appariement et d'extraction ; Cependant, elles ont l'inconvénient majeur de nécessiter un modèle a priori qui n'est pas toujours disponible ou extrêmement difficile à obtenir dans le cas des environnements complexes en milieu urbain). Il existe une autre méthode appelée "visiodométrie" qui estime la translation roto-planaire entre les images en utilisant la corrélation de phase au lieu de l'extraction de caractéristiques.

L'avantage principal apporté par les méthodes de localisation absolue par rapport aux méthodes de localisation relative est l'élimination des erreurs cumulatives. En faisant l'acquisition séquentiellement de données absolues n'ayant pas de relation consécutive avec la donnée précédente nous évitons l'accumulation des erreurs et par conséquence le phénomène de dérive rencontré avec la localisation relative. Cependant, la localisation devient dépendante de la visibilité des éléments informatifs, qu'ils soient actifs ex. Satellites GPS ou passifs ex. Amers.

La mise en place d'un système fiable à base d'une seule approche de localisation (absolue ou relative) peut s'avérer coûteux. Spécialement pour le cas de la localisation absolue qui pour être fiable et précise nécessitera forcément de lourds investissements en matière de capteurs et/ou d'aménagement de l'environnement. Dans l'idée de développer des systèmes de localisation précis qui pourront être intégrés dans la plupart des véhicules futurs sans trop avoir d'impact sur le prix de ces derniers, les travaux de recherche se sont donc orientés vers une localisation hybride [ABGL13, HNT10, JC09, NGG07, GGLV12, TMZIUMGS06, PZ04, LJ05, ZPP11a, ANL03, CBWC12, BS90, BDW95].

L'hybridation de ces deux approches de localisation à pour but d'améliorer la

localisation en compensant mutuellement les lacunes des méthodes précédemment décrites (dérive à long terme pour le positionnement relatif et le problème de masquage (occultation) pour le positionnement absolu). Pour mettre en œuvre cette combinaison des informations des deux approches, il est nécessaire d’employer des processus de fusion de données. Nous étudierons les méthodes de fusion de données employées généralement pour la localisation en robotique mobile : les méthodes de filtrage Bayésien. Dans nos travaux de recherche, nous allons étudier les adaptations de ces méthodes de filtrage à la localisation à dynamique rapide. Après l’étude des différentes approches appliquées et adaptées à la localisation de véhicules routier, le travail consistera à développer un filtre “coopératif réactif” s’inspirant et améliorant des méthodes de la littérature afin d’obtenir des performances en égo-localisation garantissant une meilleure robustesse aux bruits et aux aléas de l’environnement (ie. les canyons urbains qui causent des occultations et erreurs de mesures GPS comme le montre la figure 3.1).

3.2 Modélisation cinématique du véhicule

La localisation précise d’un véhicule à l’aide de données capteurs multiples nécessite un modèle d’évolution de cet ego-véhicule. Une modélisation simple et fidèle permet l’implémentation d’approches rapides et efficaces en matière de localisation. Les travaux de recherche accomplis dans [Bad09] et [Ven03] permettent d’avoir les informations nécessaires sur les référentiels et les modélisations possibles d’un véhicule routier. Ceci afin de choisir le modèle le plus adapté à l’application visée. Les points suivants présentent le modèle d’évolution du véhicule et les référentiels les plus utilisés pour de tels travaux.

3.2.1 Référentiel

Il existe plusieurs choix possibles de référentiel pour décrire la dynamique d’un véhicule. Les différents référentiels existants sont présentés dans [Bad09, Ven03] (ex : repères roues, repère aire de contact, repère intermédiaire, repère caisse, etc.). Nous portons notre intérêt sur deux repères plus précisément : Le repère inertiel et le repère caisse ou véhicule.

1. Repère Inertiel

C’est un repère Galiléen lié à la route et centré en un point fixe du plan parcouru par le véhicule. Ce repère est centré en O et est noté $R(O, \vec{X}, \vec{Y}, \vec{Z})$ selon la figure 3.2 telle que $\vec{Y} = \vec{Z} \wedge \vec{X}$, sachant que :

O est un point appartenant au plan de la route.

\vec{Z} est un vecteur ascendant perpendiculaire au plan de la route.

\vec{X} est un vecteur arbitraire horizontal au sol.

L'étude de la trajectoire du véhicule sera faite par sa description sur le plan de la route défini par (O, \vec{X}, \vec{Y}) . Le cap du véhicule sera mesuré à partir de l'angle θ formé par l'axe \vec{X} et le vecteur vitesse du véhicule \vec{V}_{lon} .

1. Repère Caisse

Ce repère est lié au centre de gravité G du véhicule. Le repère caisse ou véhicule peut donc être noté $R(G, \vec{X}_1, \vec{Y}_1, \vec{Z}_1)$. Pour ce repère :

\vec{X}_1 : est horizontal, prend son origine à G et est orienté vers l'avant du véhicule.

\vec{Z}_1 : est colinéaire à \vec{Z} au point de départ.

$\vec{Y}_1 = \vec{Z} \wedge \vec{X}_1$.

En appliquant ce référentiel, le cap du véhicule peut être exprimé par la différence d'orientation par rapport à celle initialisée au départ.

3.2.2 Le modèle Bicyclette




FIGURE 3.2 – Modélisation en modèle Bicyclette

Il existe une multitude de modèles simplifiés permettant d'étudier le comportement dynamique d'un véhicule [VGKB04, SGFR94]. Le modèle présenté et étudié par la suite se caractérise par sa simplicité et son efficacité (voir figure 3.2). Comme son nom l'indique, le modèle bicyclette définit le modèle du véhicule à l'aide de deux roues au total (semblable à un vélo, d'où le nom bicyclette) [NR95]. Ce modèle considère les principes suivants : Que le véhicule évolue sur une route parfaitement plane et collée au plan horizontale ($\vec{X}_Z = \vec{V}_Z = \vec{0}$), il n'y a pas de glissement. La longueur de l'essieu l est toujours constante, l'angle de braquage de la roue directrice est toujours connu et compris dans l'intervalle $[0, \frac{\pi}{2}]$, le point de contact entre chaque roue et le sol et le centre de gravité sont alignés, la masse et l'inertie des roues sont négligées et que les odomètres sont montés sur les roues arrière [Lan06, Abu05, Bon05].

Le modèle cinématique décrit par l'expression mathématique 3.1 fournit la localisation de l'égo-véhicule \vec{X}_{k+1} en se basant sur sa dernière position connue \vec{X}_k et des mesures des capteurs proprioceptifs. $\vec{X}_k = (X_k, Y_k, \theta_k)$ est le vecteur d'état de l'égo-

véhicule informant sur sa position et son orientation actuelle. Dans le modèle 3.1, δ_S représente la distance longitudinale parcourue par l'égo-véhicule entre deux instants. Cette distance peut être obtenue à l'aide des odomètres montés sur les roues arrières en appliquant le calcul suivant : $\delta_S = dist_k - dist_{k-1} = Vit_k \cdot \Delta T$. δ_θ représente la variation du cap du véhicule entre deux instants et est obtenu à l'aide des mesures de la centrale inertielle (gyroscope), $\delta_\theta = \omega_k \cdot \Delta T$ tel que ω_k la vitesse angulaire du lacet du véhicule autour de l'axe vertical Z à l'instant k . ψ représente l'angle de braquage de la roue directrice obtenu par mesure à l'aide d'un codeur d'angle au volant.

$$\begin{aligned} X_{k+1} &= X_k + \delta_S \cdot \cos\left(\theta_k + \frac{\delta_\theta}{2}\right) \cdot \cos \psi_k \\ Y_{k+1} &= Y_k + \delta_S \cdot \sin\left(\theta_k + \frac{\delta_\theta}{2}\right) \cdot \cos \psi_k \\ \theta_{k+1} &= \theta_k + \delta_\theta \end{aligned} \tag{3.1}$$

3.2.3 Avantages et inconvénients du modèle Bicyclette

Comme indiqué précédemment, ce modèle cinématique se distingue par sa simplicité et son efficacité. Le rapport précision/complexité étant satisfaisant, nous avons fait le choix d'employer cette modélisation cinématique pour les tests et le développement. Néanmoins, une meilleure précision de modélisation est toujours possible à moyen et long terme en transposant le travail développé en matière de localisation hybride sur d'autres modèles d'évolution du véhicule, plus complexes et plus précis. En effet, les systèmes utilisant la modélisation bicyclette pour la localisation avec de l'odométrie sont plus sujets aux dérives à cause du patinage et du glissement des roues qui ne sont pas pris en compte. Notez que, les mesures de distance et d'angle accumulent les erreurs au fil du temps, mais pas la mesure de la vitesse. Pour avoir une information absolue ou une information complète et cohérente, l'approche par hybridation associe un capteur GPS aux autres capteurs sujets aux erreurs cumulatives afin de compenser les dérives. Le modèle bicyclette est donc tout à fait adéquat. Il reste cependant des erreurs qui limitent ce modèle puisqu'il ne les gère pas, telles que les dérives causées par des diamètres de roues différents (causés par l'usure), le non alignement des roues, les contacts roues/chaussée etc. Ces erreurs présentent un caractère aléatoire et dépendent de la qualité des pneumatiques et de la chaussée ainsi que des conditions météorologiques. Gérer ces différents facteurs revient à utiliser des modèles intégrant la mécanique du véhicule tels que vu dans [Ven03] ainsi que des modèles de comportement sur les chaussées dans différentes conditions climatiques. L'intérêt principal du modèle bicyclette est qu'il nous permet de calculer simplement

les matrices jacobiennes (dérivées partielles) de la matrice d'évolution, de commande et de mesure ; utiliser un modèle d'évolution plus précis mais plus complexe rendrait ces calculs bien plus difficiles à gérer en temps réel.

3.3 Prise en compte des bruits de mesures

La qualité de la localisation fournie par un estimateur est toujours dépendante de la qualité des informations fournies par les différents capteurs tel que le GPS, l'odomètre, le gyromètre, l'accéléromètre ou le codeur d'angle au volant. L'hybridation de la donnée GPS pour une localisation meilleure dépend donc principalement de la qualité des données supplémentaires (proprioceptives) disponibles.

Les approches par hybridation du GPS avec d'autres capteurs proprioceptifs permettent une estimation de la localisation du véhicule avec ou sans la disponibilité des données GPS. Ceci est possible avec les estimateurs de type bayésien en phase de prédiction où les données proprioceptives permettent d'obtenir une continuité de l'estimé a priori de l'évolution du véhicule tout en introduisant des bruits dits de processus ou de système. Ces bruits viennent des erreurs des données capteurs proprioceptifs, se cumulent aux bruits de modélisation attribués au modèle véhicule. L'ensemble des bruits permet d'estimer la vraisemblance de la prédiction notée sous la forme d'une matrice de variance covariance $P_{k|k-1}$. Les données proprioceptives permettent de continuer à estimer la position du véhicule entre deux mesures GPS fournies à des fréquences faibles. Ces données proprioceptives sont la source qui permet à l'estimateur de continuer à fournir une position du véhicule dite à l'estime (prédiction) lorsque le signal GPS souffre de masquage.

L'information de localisation dans le domaine de l'aide à la conduite n'est généralement qu'une fonction qui transmet une information de positionnement à des modules de traitement de données consacrés aux applications développées. En effet, la localisation doit fournir une information à une plus grande fréquence que celle d'un GPS classique essentiellement dans les applications temps réel. Toutefois, les données des capteurs proprioceptifs sont la principale cause de problèmes de dérive pour les estimateurs. La dérive résulte du cumul des erreurs présentes dans l'information inertielle.

Les points majoritairement considérés afin de corriger les mesures des capteurs proprioceptifs sont d'un côté les caractéristiques techniques et technologiques des capteurs et d'un autre côté la méthode employée pour la collecte des données [BS90, BDW95, Mar99].

Considérant que, pour ce type de capteurs, les défauts dominants traités sont le biais et le bruit de mesures, les mesures sont généralement considérées comme dans

[Suk00] suivant l'équation 3.2 :

$$M_i = m_i + b_m + \nu \quad (3.2)$$

M_i représente la mesure fournie par le capteur qui elle même contient m_i qui est la vraie mesure, b_m est le biais du capteur, et ν représente le bruit blanc du signal.

Les travaux effectués par le LIVIC dans le domaine du débruitage, dont une partie est disponible dans la thèse de Ndjeng [NN09], traitent la question du débruitage des données issues de capteurs proprioceptifs.

Ces travaux concluent que le débruitage par seuillage d'ondelettes de type Coifflet ayant 4 moments nuls s'avère être la méthode la plus efficace pour gérer des données provenant d'une centrale inertielle du type VG400. Cependant, procéder à un pré-traitement en ligne des données pour une application en temps réel reste un choix difficilement applicable. Faisant un compromis entre temps d'exécution, ressources informatiques et atténuation des bruits de mesures, aucun pré-traitement n'est fait dans le cadre des applications de localisation qui vont suivre. Les bruits de mesure seront tout de même pris en compte comme décrit dans l'équation 3.2. Les méthodes de fusion qui suivront pourront donc tout à fait prendre en charge les erreurs de mesures des différents capteurs proprioceptifs à l'aide des variances attribuées aux différentes sources, sous condition que ces variances traduisent au mieux les erreurs des données fournies par ces capteurs.

Chapitre 4

Fusion multicateurs pour la localisation de véhicules routiers

Sommaire

4.1	Introduction	35
4.2	Le filtre de Kalman Étendu	37
4.2.1	Introduction	37
4.2.2	Le filtre de Kalman Étendu : théorie et implémentation	37
4.2.3	Application de l'EKF à la localisation des véhicules routiers	42
4.2.4	Avantages et limites de l'EKF	43
4.3	Le filtre particulaire	44
4.3.1	Introduction	44
4.3.2	Principe d'une approche multi-hypothèses	45
4.3.3	Le filtre particulaire	45
4.3.4	Application du PF à la localisation des véhicules routiers	52
4.3.5	Avantages et limites du filtre à particules	54
4.3.6	Conclusion	54

4.1 Introduction

Au cours de la dernière décennie, la recherche en systèmes de transport intelligent dans le domaine routier (ITS-R : Intelligent Transport Systems applied to Road applications) a été très active, en ciblant le développement de navigateurs, des systèmes avancés d'assistance à la conduite (ADAS : Advanced Drive Assistance Systems), des

véhicules automatisés et des systèmes de sécurité (CASS : Collision Avoidance Support Systems). Pour ce genre d'applications, des informations de positionnement à haute intégrité sont nécessaires.

Les ITS sur le marché de l'industrie doivent avoir un minimum de coût, facile à installer et qu'à maintenir, ainsi qu'ils doivent fournir un positionnement en continu (même en cas de panne du signal GNSS) pour les systèmes de localisation. Dans ces conditions, le traitement et la fusion des informations en provenance de différentes sources déjà intégrés est l'une des meilleures solutions. L'hybridation du GPS est généralement faite avec d'autres capteurs proprioceptifs : IMU (unité de mesure inertielle), Gyromètre, Odomètre, etc. Pour ceci on a besoin de méthodes mathématiques pour la fusion de données et l'estimation d'état. Parmi les plus connues, on a le filtre de Kalman qui est largement utilisé, mais n'est optimal que pour les systèmes linéaires. Dans les applications routières, les modèles sont généralement non-linéaires, ce qui conduit à l'utilisation de méthodes sous-optimales telles que l'EKF (filtre de Kalman étendu). Cependant, les fortes non-linéarités des équations peuvent conduire à des problèmes d'instabilité et de divergence avec l'EKF.

Ainsi, la recherche internationale s'est concentrée sur la question de la localisation du véhicule robuste et précise, en cherchant à améliorer la donnée uniquement fournie par du GNSS (Global Navigation Satellite System) par la fusion avec des données provenant des capteurs proprioceptifs. Les méthodes d'estimation bayésiennes récursifs sont la solution la plus populaire pour l'estimation d'état et de mesure des données de fusion (EKF, UKF, DD1, DD2 etc.).

Certaines nouvelles méthodes ont été développées afin de limiter les effets du problème de la linéarisation et du calcul de Jacobiennes (utilisé dans l'EKF) et ainsi, améliorer l'estimation non linéaire. Chacune de ces méthodes utilise un autre moyen de linéarisation en ayant souvent le même ordre de complexité algorithmique que l'EKF. Quelques autres variantes du filtre de Kalman ont ainsi été développées comme la différence divisée d'ordre premier et deuxième (DD1 et DD2) et le filtre de Kalman inodore (UKF). Ces variantes ainsi que les approches multi-hypothèses telles que le filtre particulaire (PF) sont basées sur l'idée qu'il est plus facile d'approcher une distribution gaussienne que d'approcher une fonction non-linéaire. La linéarisation est ici réalisée par régression linéaire des fonctions statistiques ou par le biais de points d'échantillonnage de l'estimation de l'État. Ces variantes du filtre de Kalman restent néanmoins des solutions sous-optimales avec l'hypothèse d'un bruit gaussien. L'étude accomplie par cette thèse vise à exploiter leurs avantages et limiter leur inconvénients. Une comparaison théorique et expérimentale de ces méthodes dans le contexte de localisation du véhicule a fait l'objet de travaux précédents au LIVIC [Sei06, Lan06, NN09]. Ces travaux ont démontré les différences théoriques et applicatives pour une

localisation dynamique d'un égo-véhicule. En synthèse de ces travaux, les variantes du filtre de Kalman semblent dans le cas général afficher des performances semblables, ce qui nous amène à étudier l'EKF comme approche comparative de référence. La comparaison se fera aussi avec le filtre particulière afin d'avoir une approche multi-hypothèses comme deuxième référence de comparaison.

4.2 Le filtre de Kalman Étendu

4.2.1 Introduction

Dans cette partie nous introduisons la théorie bayésienne afin de poser les fondements des filtres développés dans ces travaux et de pouvoir essentiellement expliciter les notions de probabilités a posteriori et a priori et celle de vraisemblance dans le filtre de Kalman. Ces bases nous serviront à valider la formulation mathématique du filtre de Kalman et à détailler les formulations de chacune de ses étapes : initialisation, linéarisation (calcul des Jacobiennes), prédiction, et estimation.

4.2.2 Le filtre de Kalman Étendu : théorie et implémentation

Le filtre de Kalman étendu (EKF) est la version non linéaire du filtre de Kalman (KF). Dans le cas des modèles d'évolution bien définis, l'EKF est le plus largement utilisé pour l'estimation d'état non linéaire pour les systèmes de navigation et à base de GPS.

Le principe de l'EKF peut se résumer en deux étapes :

L'étape de prédiction : L'utilisation de l'état précédent connu du véhicule et des mesures des capteurs proprioceptives permet de produire une estimation de l'état actuel du véhicule nommé état prédit auquel on attribue une incertitude.

L'étape d'estimation ou de mise à jour : Le filtre corrige sa prédiction à l'aide de la mesure GPS ou de données extéroceptives (cartographie, balises, etc.). La réévaluation filtre l'état du véhicule et son incertitude en utilisant une moyenne pondérée entre les données correctives et la prédiction (poids attribué à l'état qui a la plus grande précision par le gain Kalman).

Théorie :

Ici nous allons à partir d'une représentation d'état d'un système physique réel¹ et en appliquant les notions bayésienne, retrouver les formulations de base du filtre

1. D : matrice de transfert direct, nulle pour un système physique réel

de Kalman étendu. Cette démarche peut être retrouvée facilement dans plusieurs ouvrages d'automatique et de mathématiques appliquées. Pour cette raison, le but ici n'est pas de reproduire les étapes mathématiques ni de trop détailler. Le but de ce qui suit est de permettre au lecteur de comprendre le principe du filtre de Kalman.

Soit un système décrit par les équations d'état suivantes :

$$\begin{cases} X_k = A_{k-1}X_{k-1} + B_{k-1}u_{k-1} + \nu_{k-1} \\ Z_k = C_kX_k + \eta_k \end{cases} \quad (4.1)$$

On suppose que la condition initiale X_0 est gaussienne, de moyenne \bar{X}_0 , la suite ν est un bruit blanc gaussien, de matrice de covariance Q , la suite η est un bruit blanc gaussien. Les bruits ν et η et la condition initiale X_0 sont mutuellement indépendants.

L'équation de prédiction d'état du filtre de Kalman est l'application directe de celle de la représentation d'état qui donne l'équation suivante :

$$\hat{X}_{k|k-1} = A_{k-1}\hat{X}_{k-1|k-1} + B_{k-1}u_{k-1} + \nu_{k-1} \quad (4.2)$$

Le Filtre de Kalman étant un estimateur sans biais, on peut écrire :

$$\begin{aligned} P_{k|k-1} &= E \left[(X_k - \hat{X}_{k|k-1})(X_k - \hat{X}_{k|k-1})^T \right] \\ P_{k|k} &= E \left[(X_k - \hat{X}_{k|k})(X_k - \hat{X}_{k|k})^T \right] \end{aligned} \quad (4.3)$$

Le rôle du filtre de Kalman est de minimiser l'écart entre l'état réel X_k et celui estimé $\hat{X}_{k|k}$. La trace de la matrice $P_{k|k}$ peut être notée :

$$tr(P_{k|k}) = (X_k - \hat{X}_{k|k})(X_k - \hat{X}_{k|k})^T$$

Le filtre de Kalman a pour but de minimiser cette trace par le moyen d'une correction linéaire avec un gain K_k . En fonction de l'importance de la variance du bruit de mesure par rapport à la variance de l'estimé prédite, le filtre va accorder plus d'importance à la prédiction ou à la mesure.

- Quand l'incertitude de mesure est faible $R_\eta \rightarrow 0 \implies K_k \rightarrow C^{-1}$
- Quand l'incertitude de l'estimé est faible $P_{k|k} \rightarrow 0 \implies K_k \rightarrow 0$

A partir des équations 4.1 et 4.2 on calcul $(X_k - \hat{X}_{k|k-1})$.

$$(X_k - \hat{X}_{k|k-1}) = A_{k-1}(X_{k-1} - \hat{X}_{k-1|k-1}) + \nu_{k-1} \quad (4.4)$$

En remplaçant $(X_k - \hat{X}_{k|k-1})$ dans $P_{k|k-1}$ (définie dans l'équation 4.3) on obtient :

$$P_{k|k-1} = E \left[(A_{k-1}(X_{k-1} - \hat{X}_{k-1|k-1}) + \nu_{k-1})(A_{k-1}(X_{k-1} - \hat{X}_{k-1|k-1}) + \nu_{k-1})^T \right]$$

$$P_{k|k-1} = E \left[(A_{k-1}(X_{k-1} - \hat{X}_{k-1|k-1}) + \nu_{k-1})((X_{k-1} - \hat{X}_{k-1|k-1})^T A_{k-1}^T + \nu_{k-1}^T) \right]$$

$$P_{k|k-1} = A_{k-1} E \left[(X_{k-1} - \hat{X}_{k-1|k-1})(X_{k-1} - \hat{X}_{k-1|k-1})^T \right] A_{k-1}^T + E \left[\nu_{k-1} \nu_{k-1}^T \right]$$

$$P_{k|k-1} = A_{k-1} P_{k-1|k-1} A_{k-1}^T + R_{\nu_{k-1}} \quad (4.5)$$

L'équation résultante 4.5 couplée avec l'équation 4.2 forment les couples d'équations de prédiction de Kalman employés par la suite dans la formulation 4.11.

La partie suivante va traiter l'étape de mise à jour et de calcul du gain. Dans ce qui suit, on explique le principe de correction employé dans le filtre de Kalman et nous en déduisons la formule du gain pour la correction.

$$\hat{X}_{k|k} = \hat{X}_{k|k-1} + K_k \left[Z_k - C_k \hat{X}_{k|k-1} \right] \quad (4.6)$$

Dans l'équation 4.6 le principe de correction linéaire est illustré. $\hat{X}_{k|k}$ étant l'estimé calculée en faisant une correction linéaire de la prédiction $\hat{X}_{k|k-1}$ avec un gain de Kalman K_k entre la mesure Z_k et l'observation $C_k \hat{X}_{k|k-1}$.

En remplaçant l'expression de Z_k notée dans la représentation d'état 4.1 dans l'équation expliquant le principe de correction linéaire 4.6, on obtient l'expression suivante :

$$\hat{X}_{k|k} = \hat{X}_{k|k-1} + K_k \left[C_k X_k + \eta_k - C_k \hat{X}_{k|k-1} \right]$$

$$(\hat{X}_{k|k} - X_k) = (I - K_k C_k)(\hat{X}_{k|k-1} - X_k) + K_k \eta_k$$

$$(\hat{X}_{k|k} - X_k)^T = (\hat{X}_{k|k-1} - X_k)^T (I - K_k C_k)^T + \eta_k^T K_k^T$$

En utilisant les deux dernières expressions pour exprimer $P_{k|k}$ comme noté dans l'équation 4.3 on peut écrire :

$$P_{k|k} = (I - K_k C_k) P_{k|k-1} (I - K_k C_k)^T + K_k R_{\eta_k} K_k^T \quad (4.7)$$

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

Cette expression obtenue est celle employée pour la mise à jour des variances/covariances dans le filtre de Kalman. La notation 4.12 utilise une variante simplifiée de cette même équation 4.7 afin de pallier certains problèmes de singularité et d'éviter la divergence du filtre.

Le calcul du gain se fait en employant cette dernière équation de mise à jour notée ci-dessus en 4.7. On commence par développer l'expression obtenue.

$$P_{k|k} = (I - K_k C_k) P_{k|k-1} (I - K_k C_k)^T + k_k R_{\eta_k} K_k^T$$

$$P_{k|k} = P_{k|k-1} - K_k C_k P_{k|k-1} - P_{k|k-1} C_k^T K_k^T + K_k (C_k P_{k|k-1} C_k^T + R_{\eta_k}) K_k^T$$

En employant le principe de la factorisation de Cholesky et dans un but de simplification, on pose : $C_k P_{k|k-1} C_k^T + R_{\eta_k} = S_k S_k^T$

l'expression de $P_{k|k}$ donne alors :

$$P_{k|k} = P_{k|k-1} - K_k C_k P_{k|k-1} - P_{k|k-1} C_k^T K_k^T + K_k S_k S_k^T K_k^T$$

$$P_{k|k} = P_{k|k-1} - K_k S_k S_k^{-1} C_k P_{k|k-1} - P_{k|k-1} C_k^T (S_k^T)^{-1} S_k^T K_k^T + K_k S_k S_k^T K_k^T + \psi_k \psi_k^T - \psi_k \psi_k^T$$

$$P_{k|k} = P_{k|k-1} + (K_k S_k - \psi_k)(K_k S_k - \psi_k)^T - \psi_k \psi_k^T$$

Afin que le gain K_k minimise $P_{k|k}$ il est impératif que $(K_k S_k - \psi_k) = 0 \Rightarrow P_{k|k}^{max} = P_{k|k-1} - \psi_k \psi_k^T$

Le gain qui minimise $P_{k|k}$ est donc exprimé par : $K_k = \psi_k S_k^{-1}$, en remplaçant dans cette expression ψ_k et S_k par leur expressions tel que :

$\psi_k = P_{k|k-1} C_k^T (S_k^T)^{-1}$ et $S_k S_k^T = C_k P_{k|k-1} C_k^T + R_{\eta_k}$ le gain de Kalman est défini par 4.8.

$$K_K = P_{k|k-1} C_k^T [C_k P_{k|k-1} C_k^T + R_{\eta_k}]^{-1} \quad (4.8)$$

A ce stade, on a obtenu toutes les briques de formulations mathématiques pour un filtre de Kalman qui sont les équations de prédiction et d'estimation (correction, mise à jour). Il reste à implémenter la méthode pour un système non linéaire tel que le notre en adoptant une linéarisation autour de l'estimé. La linéarisation autour de l'estimé se fait en appliquant des dérivées partielles sur les différentes matrices du système, ces nouvelles matrices à base de dérivées partielles sont les Jacobiennes.

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

Implémentation :

L'implémentation du filtre commence par une étape d'initialisation dans laquelle on donne des valeurs initiales aux éléments suivants :

X : Vecteur d'état $(x, y, \theta)^T$.

U : Vecteur de Commande.

P : Matrice de Variance/Covariance.

w : Bruit de Processus.

Q : Matrice de Variance/covariance représentant le bruit de Processus.

v : Bruit de Mesure.

R : Matrice de Variance/covariance représentant le bruit de Mesure.

Y : Vecteur de Mesures.

Les matrices Jacobiennes A et H sont dérivées respectivement de f la fonction d'évolution (ou de transition) et h la fonction d'observation (ou de mesure). La prédiction est faite en employant la matrice d'évolution A . La correction se fait avec le gain de Kalman qui ajuste le vecteur d'état et la matrice de variance-covariance.

Initialisation :

$$\begin{aligned}\hat{X}_0 &= E[X_0] \\ P_0 &= E[(X_0 - \hat{X}_0)(X_0 - \hat{X}_0)^T] \\ Q_0 &= E[(w - \bar{w})(w - \bar{w})^T] \\ R_0 &= E[(v - \bar{v})(v - \bar{v})^T]\end{aligned}\tag{4.9}$$

Jacobiennes :

$$\begin{aligned}A_{xk} &= \nabla_x f(X, u_k, \bar{w})|_{X=\hat{X}_{k-1|k-1}, U_{k-1}} \\ H_k &= \nabla_x h(X, \bar{v})|_{X=\hat{X}_{k|k-1}}\end{aligned}\tag{4.10}$$

Prédiction :

$$\begin{aligned}\hat{X}_{k|k-1} &= f(\hat{X}_{k-1|k-1}, U_{k-1}) \\ P_{k|k-1} &= A_{xk}P_{k-1|k-1}A_{xk}^T + Q_k\end{aligned}\tag{4.11}$$

Estimation :

$$\begin{aligned}K_k &= P_{k|k-1}H_k^T[H_kP_{k|k-1}H_k^T + R_k]^{-1} \\ \hat{X}_{k|k} &= \hat{X}_{k|k-1} + K_k[Y_k - H_k\hat{X}_{k|k-1}] \\ P_{k|k} &= (I - K_kH_k)P_{k|k-1}\end{aligned}\tag{4.12}$$

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

4.2.3 Application de l'EKF à la localisation des véhicules routiers

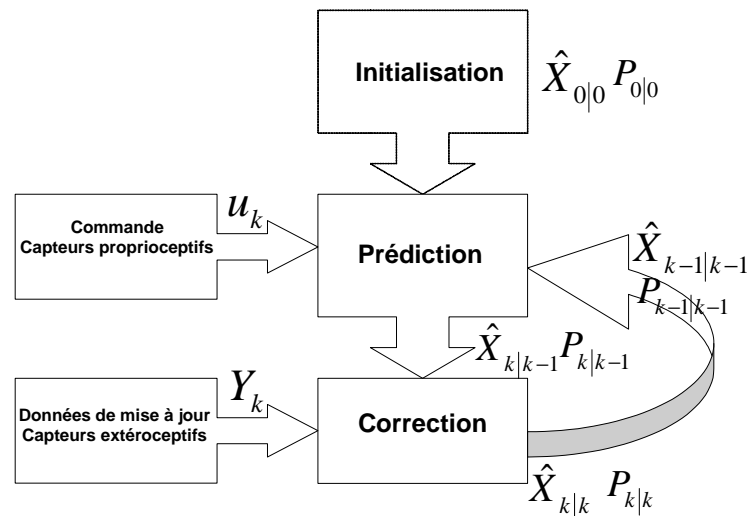


FIGURE 4.1 – Égo-localisation par Filtrage de Kalman

La localisation de l'égo-véhicule par le filtre de Kalman étendu suivra les étapes indiquées par la figure 4.1. Sur cette figure nous pouvons voir qu'après une étape d'initialisation (détaillée dans 4.9), l'état initial ainsi que son incertitude associée sont générés et sont notés respectivement dans la figure 4.1 comme \hat{X}_0 et P_0 . Ensuite vient l'étape de prédiction détaillée par les équations 4.11. La prédiction fait usage du modèle d'évolution décrit dans 3.2.2. Le modèle est linéarisé autour du dernier état connu suivant le principe des Jacobiennes décrites par 4.10. La linéarisation se fait en considérant le dernier état connu (initialisation, prédiction ou mise à jour) comme le véritable état du véhicule (ce qui n'est qu'une approximation). La prédiction est appliquée suivant le modèle linéarisé faisant appel aux données fournies par les capteurs proprioceptifs. La prédiction est appliquée afin de fournir un état probable du véhicule à l'instant présent en y associant une incertitude. Le résultat de la prédiction est donc l'état prédit $\hat{X}_{k|k-1}$ et son incertitude $P_{k|k-1}$. Les données proprioceptives provenant des capteurs étant beaucoup plus rapides que celles utilisées en extéroceptif (GPS bas coûts), plusieurs étapes de prédictions se succèdent avant l'appel d'un processus (étape) de mise à jour ou de correction (voir figure 4.1). La fréquence des capteurs proprioceptifs est généralement de 100 à 500 Hz et le GPS est le plus souvent à 1 Hz pour les bas coûts. En traitant les données qui arrivent en

temps réel, le processus multiplie les étapes de prédiction en considérant à chaque instant k l'état prédit auparavant comme le précédent état connu $\hat{X}_{k-1|k-1}$ et son incertitude devient $P_{k-1|k-1}$. Une fois une donnée extéroceptive disponible, vient la phase de correction (mise à jour). En appliquant la mise à jour détaillé par le groupe d'équations 4.12, le filtre vient réestimer l'état du véhicule en corrigeant l'état calculé *a priori* $\hat{X}_{k|k-1}$ (prédiction) par une donnée GPS actuelle Y_k . La correction se fait en appliquant le gain de Kalman K_k qui permet de se rapprocher de la zone de positionnement ayant la meilleure incertitude entre l'état prédit et l'état fourni par la mesure GPS. Cette étape délivre en sortie un état dit *a posteriori* $\hat{X}_{k|k}$ ainsi que son incertitude associée $P_{k|k}$ calculée dans le cas général suivant 4.7 et dans notre application suivant 4.12.

4.2.4 Avantages et limites de l'EKF

En résumé, le filtre de Kalman est l'estimateur optimal de minimum de variance *a posteriori* pour les systèmes linéaires. Le principe de fonctionnement du filtre de Kalman prend en compte un état précédent et un modèle d'évolution du système. La stabilité et la convergence rapide du filtre dépendent aussi des réglages de l'algorithme, essentiellement le calibrage des bruits de mesures et de processus. Pour la localisation des véhicules routiers à forte dynamique non linéaire, le filtre de Kalman linéaire n'est pas adapté. Les véhicules routiers étant des systèmes à dynamique rapide et généralement avec des modèles non linéaires et dérivables, la localisation se fait donc à l'aide d'une adaptation du filtre de Kalman pour les systèmes non linéaires. On se retrouve à employer des solutions sous optimales, mieux adaptées à notre problématique. Parmi les plus connues de ces solutions nous citons le Filtre de Kalman Étendu (EKF).

L'EKF, comme présenté auparavant, applique les mêmes étapes que le filtre de Kalman linéaire en utilisant une linéarisation (Jacobiennes) du modèle d'évolution au lieu du modèle non linéaire lui-même. Les limites de cette approche peuvent être liées au système et à sa modélisation par rapport à la condition de dérivabilité nécessaire pour le calcul des Jacobiennes, condition qui n'est pas toujours satisfaite. Aussi la linéarisation au premier ordre en série de Taylor peut tronquer des termes significatifs dans le cas de non linéarité d'ordre 2 ou plus. Les limites peuvent aussi concerner les différents bruits à prendre en compte, l'évaluation de ces bruits est toujours une étape cruciale et conditionnée par des approximations (condition de bruits gaussien). Finalement, il faut noter que l'EKF ne garantit aucune convergence théorique. En effet, la linéarisation se faisant autour d'un pseudo état réel du système qui n'est que la dernière estimation d'état connue. Si le passage au prochain état du véhicule n'est

pas pris en compte par l'espace d'état atteignable par prédiction à l'aide du modèle linéarisé, le modèle se retrouve hors de l'espace d'état d'évolution du véhicule et il est possible que le filtre diverge.

4.3 Le filtre particulaire




FIGURE 4.2 – Schématisation de la localisation multi-hypothèses

4.3.1 Introduction

Le filtrage particulaire aussi connu sous le nom de méthodes de Monte-Carlo séquentielles est une méthode numérique permettant d'approcher la distribution de probabilité de l'état au moyen de la distribution empirique de particules.

Chaque particule représente une possible configuration de l'état estimé. On attribue à chaque particule un poids qui permet de juger la cohérence de cet échantillon suivant la probabilité conditionnelle de l'état tout en connaissant les observations.

Le filtre particulaire est une méthode dite "en-ligne" analogue aux méthodes de Monte-Carlo par chaînes de Markov qui elles sont des méthodes 'hors-ligne' (donc

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

a posteriori) et souvent similaires aux méthodes d'échantillonnage d'importance [HSG06].

Le filtre particulaire peut être plus rapide que les méthodes de Monte-Carlo par chaînes de Markov. Il constitue souvent une alternative au filtre de Kalman étendu avec l'avantage qu'avec suffisamment d'échantillons, il approche l'estimée Bayésienne optimale. Le PF peut être plus robuste que le filtre de Kalman, reste à faire un compromis entre le temps de calcul et la précision.

Ces deux dernières approches peuvent aussi être combinées en utilisant un filtre de Kalman comme une proposition de distribution pour le filtre particulaire permettant d'avoir une meilleure répartition des particules et une convergence plus rapide.

4.3.2 Principe d'une approche multi-hypothèses

Ce type d'approche repose sur un grand nombre de possibilités (hypothèses). Ces possibilités sont générées par les états des particules employées pour l'estimation d'état du système. Chaque particule à chaque étape représente un possible état du système (une hypothèse). La force de l'approche multi-hypothèses est l'emploi d'une multitude de particules. Les particules vont explorer plusieurs possibilités dans l'espace d'état, elles vont donc s'éloigner ou se rapprocher du véritable état du système. Le nuage construit par les particules va permettre de générer une mesure de probabilité autour de l'état estimé du système. L'état du système est quand à lui estimé à l'aide d'une notation (pondération) des particules suivant leur vraisemblance. La fusion des états des particules pondérés par leurs notations donne donc un état estimé global. Plus le nombre de particules (hypothèses) est élevé plus l'état estimé se rapproche de l'optimum du point de vue de la densité de probabilité a posteriori de l'état du système étudié.

4.3.3 Le filtre particulaire

Comme pour toutes les méthodes de Monte Carlo (multi-hypothèses), ce filtre s'appuie sur l'utilisation d'échantillons appelés particules. D'où le nom de filtre à particule ou filtre particulaire. Ce filtre traite le problème de filtrage d'un point de vue probabiliste. Ainsi le filtre revient à considérer l'estimation de la loi de probabilité de l'état du système X_k conditionnellement à l'ensemble des mesures $Y_1 \dots Y_k$ ce qui donne $P(X_k|Y_1 \dots Y_k)$. Cela se fait par la génération d'autant d'états que de particules en suivant le modèle de dynamique du système. Ensuite une mesure d'état est construite en fonction des observations obtenues. Cette mesure d'état X_k converge vers la mesure associée $Y_1 \dots Y_k$ grâce à la loi des grands nombres [CD02, SAC02].

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

La première des grandes variantes des filtres à particules est basée sur la procédure SIS (Sampling importance Sampling). Cette approche a été proposée dans les années 70 [Han70]. L'idée est de faire évoluer N particules indépendantes les unes des autres et de les pondérer à chaque instant K en fonction de leur vraisemblance par rapport à l'observation Y_k . L'approche de filtrage particulaire SIS nécessite la simulation d'un grand nombre d'hypothèses pour assurer la convergence. Ce type d'approche n'a connu un véritable intérêt que vers les années 80 pendant lesquelles les machines devinrent assez puissantes pour supporter la charge de calcul nécessaire. Malgré l'évolution des machines et de l'informatique, cette méthode a tendance à rassembler le nuage de particules en un seul point de l'espace d'état (convergence prématurée) et d'explosion de l'essaim lorsqu'il y a des problèmes de calibrage de bruit de processus, ce qui cause la divergence du filtre par la suite.

Afin de répondre à cette problématique, l'idée est d'assurer une bonne gestion de diversité des échantillons en gardant le nuage de particules dans une certaine norme en évitant un éparpillement ou une concentration excessive des particules. La solution proposée est la procédure SIR (Sampling-Importance Resampling) [HSG06, SAC02]. La SIR ne se contente pas que de pondérer les particules mais fait aussi une sélection à la manière des approches de sélection génétique. Les particules subissent donc une sélection suivant leurs vraisemblances respectives. La sélection se fait par l'élimination des particules non efficaces et la duplication de celles jugées efficaces toujours en se référant à la pondération associée. Cette contribution améliore fortement les performances du filtrage particulaire en augmentant considérablement le temps de calcul. Le processus de rééchantillonnage étant lourd en matière de temps de calcul, il est donc plus judicieux de le déclencher conditionnellement en mettant des critères de rééchantillonnage.

Le filtre particulaire étudié dans notre approche et appliqué à la localisation des véhicules est un filtre particulaire avec interaction SIR. Le filtre particulaire pour une application de localisation passe comme le filtre de Kalman par deux grandes étapes. Une étape de prédiction où chaque particule évolue de manière indépendante suivant le modèle d'évolution. Et une étape d'échantillonnage où chaque particule est jugée suivant sa vraisemblance par rapport à la donnée GPS reçue. Ici, dans l'étape d'échantillonnage, nous pouvons donc faire une moyenne pondérée des hypothèses obtenues. Le processus SIR intervient par la suite (si nécessaire) afin d'assurer une bonne homogénéité du nuage de particules. Le processus de localisation étant un processus critique censé informer d'autres processus en temps réel, nous ne pouvons pas nous permettre de générer une localisation uniquement à la réception d'une donnée GPS. Tout l'intérêt de notre travail est donc d'assurer une localisation dite inertielle. Ceci est satisfait par le fait de produire un état prédit après la prédiction

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

des particules. Il faut donc faire fusionner les particules au moment de la prédiction. Le choix que nous faisons est d'appliquer une moyenne simple des hypothèses ou une moyenne pondérée en utilisant les anciens poids à condition que ces poids soit toujours significatifs. Ceci consiste à faire une simple moyenne pondérée des états des particules en considérant les poids des particules égaux $w^i = 1/N$ sachant que N est le nombre de particules (répartition équiprobable). Ce fonctionnement se justifie par le fait que le poids généré après l'application de la phase d'échantillonnage peut ne plus être significatif essentiellement lorsque le véhicule change de dynamique entre deux réceptions GPS. Aussi, si le nuage de particules a été homogénéisé par un rééchantillonnage alors les particules se voient redistribuer de nouveaux poids.

La partie qui suit détaille le déroulement algorithmique du filtre particulaire pour le cas d'une égo-localisation. Comme tout filtre, le filtre particulaire commence par une initialisation.

Initialisation

Dans le but de localiser notre véhicule dans le cadre d'une application de type localisation, nous considérons une position initiale de notre véhicule représentée par le vecteur d'état $X_{init} = (x_{init}, y_{init}, \theta_{init})^T$. Ensuite nous répartissons notre nuage d'échantillons autour de cette position initiale en attribuant à chaque particule un vecteur d'état et un poids initial.

Le nombre N qui représente le nombre d'échantillons est à fixer par l'utilisateur.

Les vecteurs d'état des particules représentent une répartition gaussienne centrée autour de la position initiale connue suivant ce modèle :

Chaque particule i a un vecteur d'état $X_0^i = \begin{pmatrix} x_{init} + \epsilon_x^i \\ y_{init} + \epsilon_y^i \\ \theta_{init} + \epsilon_\theta^i \end{pmatrix}$ et un poids $w_0^i = 1/N$.

Les $(\epsilon_x^i, \epsilon_y^i, \epsilon_\theta^i)$ sont des variables aléatoires, ces variables sont ajoutées afin de représenter l'état initial sous la forme d'un nuage de particules distribuées autour de la position initiale suivant l'incertitude attribuée à cette initialisation. Les lois normales centrées de probabilité utilisées dans ce cas sont $N(0, \sigma_x)$, $N(0, \sigma_y)$, $N(0, \sigma_\theta)$ tel que les $(\sigma_x, \sigma_y, \sigma_\theta)$ sont ceux de la matrice de variance covariance de bruit.

Prédiction

Dans cette étape, à partir de la dernière position connue du véhicule et des données des capteurs proprioceptifs tel que l'odomètre et le gyroscope, nous calculons une position prédite du véhicule $X_{k|k-1}$. Elle est calculée à l'aide d'un modèle d'évolution du véhicule intégrant les données des capteurs proprioceptifs. Le modèle d'évolution est appliqué à chaque particule afin de la faire évoluer un état prédit $X_{k|k-1}^i$. Il est important d'intégrer dans cette étape de prédiction les erreurs de mesures ainsi que les

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

erreurs de modélisations sous forme de bruits. Ces bruits permettent aux particules d'évoluer chacune de manière différente, ceci favorise l'exploration de l'espace de recherche. Si ce bruit est trop faible, le filtre ne fonctionnera pas bien et les particules ne représenteront pas suffisamment la distribution d'état ou l'incertitude autour de l'état prédit pour ce cas précis. Si le bruit est trop fort sur plusieurs étapes de prédictions consécutives, le filtre pourra diverger à cause d'un éparpillement trop important des particules sachant que le rééchantillonnage n'interviendra qu'après l'étape d'échantillonnage conditionnée par une mesure extéroceptive.

L'état prédit du véhicule faisant l'objet d'une fusion des prédictions des différentes particules, son incertitude correspond à la densité de probabilité formée par le nuage de particule autour de cet état. Le calcul de l'état prédit et de son incertitude associée se fait en appliquant les deux expressions suivantes :

$$X_{Vehicule} = \sum_{i=1}^N X_{k|k-1}^i \cdot w_k^i$$

$$P(X_{Vehicule}) = \sum_{i=1}^N w_k^i (X_{k|k-1}^i - X_{Vehicule}) (X_{k|k-1}^i - X_{Vehicule})^T \quad (4.13)$$

Échantillonnage

Cette étape vise à déterminer la densité d'importance des hypothèses courantes en prenant une densité a priori $q_{opt}(X_k^i | X_{k-1}^i, Y_k)$.

Le travail consiste à réévaluer (mettre à jours) les pondérations des particules en utilisant par exemple les données de correction du capteur GPS, de l'information visuelle (odométrie visuelle, détection de voie), du Laser, du radar et/ou de la cartographie (Map-matching).

Dans cette étape on ajuste notre prédiction en pondérant les particules à l'aide de nouvelles données tout en prenant en compte les différentes incertitudes. Ceci permettra de faire ensuite une correction de la prédiction afin de produire une meilleure estimation.

Pondération

Le calcul du poids pour chaque particule est défini par l'expression 4.14. Cette formule est obtenue après intégration de la formulation de la densité d'importance dans l'équation de calcul des poids suivante :

$$w_k^i = \frac{\text{distribution cible}}{\text{distribution proposée}} = \frac{p(X_{k|k-1}^i | Y_{1:k})}{q(X_{k|k-1}^i | Y_{1:k})}$$

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

on obtient donc :

$$w_k^i \propto w_{k-1}^i p(Y_k | X_{k|k-1}^i)$$

Cette étape permet de pondérer l'importance de nos particules (vecteurs d'états) à l'aide des observations en faisant intervenir la densité d'importance citée auparavant selon la formule suivante :

$$P_k^i \propto P_{k-1}^i p(Y_k | X_{k|k-1}^i) \equiv w_k^i \propto w_{k-1}^i * P(Y_k | X_{k|k-1}^i) \quad (4.14)$$

L'application directe de cette pondération sur une particule de notre filtre donnera l'expression suivante :

$$w_k^i \propto w_{k-1}^i \cdot p(Y_k | X_{k|k-1}^i) = w_{k-1}^i \cdot \frac{1}{\sqrt{(2\pi)^{|R_k|}}} \exp\left\{-\frac{1}{2}(Y_k - \hat{Y}_k)^T [R_k]^{-1} (Y_k - \hat{Y}_k)\right\} \quad (4.15)$$

où Y_k représente le vecteur de mesure, \hat{Y}_k le vecteur d'observation et R_k la matrice de variance/covariance de bruit de mesure.

Normalisation

Après le calcul ou la mise à jour des poids et afin de garder la somme des probabilités égale à 1. Nous procédons à la normalisation des poids des particules suivant cette relation où chaque poids est divisé par la somme de tous les poids :

$$w_k^i = \frac{w_k^i}{\sum_{j=1}^N w_k^j} \quad (4.16)$$

Estimation

Après la normalisation des poids, la position du système peut être calculée au sens de l'optimalité des moindres carrés en appliquant la moyenne pondérée suivante :

$$X_{Vehicle} = \sum_{i=1}^N X_{k|k-1}^i * w_k^i \quad (4.17)$$

Une autre alternative de sélection d'état optimal dite au sens du maximum a posteriori est de prendre comme état de la particule ayant le poids le plus important, $X_{Vehicle} = X_{k|k-1}^i$ tel que $w_k^i \geq w_k^j$, $\forall j \in \{1, \dots, N\}$, $j \neq i$. L'incertitude autour de cette estimation est calculée à l'aide de l'équation 4.13 en appliquant les poids et les hypothèses mises à jours.

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

Rééchantillonnage

Le rééchantillonnage est une étape primordiale au bon fonctionnement du filtrage particulaire car il prévient la divergence du filtre particulaire en éliminant les particules de poids faible et en dupliquant celles de poids forts.

Il existe une multitude d'approches pour le rééchantillonnage ainsi que des critères de rééchantillonnage. Les rééchantillonnages étudiés et développés dans nos tests sont le rééchantillonnage Multinomial, Stratifié, Résiduel et Systématique. L'étude bibliographique des études comparatives de ces approches de rééchantillonnage [HSG06, DC05, BDH00, Hol04], parallèlement aux tests de ces approches nous a fait sélectionner l'approche de rééchantillonnage dite systématique.

L'approche de rééchantillonnage systématique utilise le principe de rééchantillonnage multinomial. Nous allons donc présenter deux brèves descriptions de ces deux approches de rééchantillonnage.

— Le rééchantillonnage Multinomial :

Ce rééchantillonnage commence par un tirage aléatoire ordonné de N variables dans l'ordre croissant suivant une loi uniforme. Les chiffres sont obtenus par application des formules suivantes $u_k = u_{k+1} \tilde{u}_k^{\frac{1}{k}}$ et $u_N = \tilde{u}_N^{\frac{1}{N}}$ avec $\tilde{u}_k \sim U[0, 1)$. Il existe une procédure de programmation simple et rapide d'exécution appelée procédure de Niclas Bergman. Une autre alternative est de générer les variables par une fonction *random* uniforme puis de réordonner le tout dans l'ordre croissant, ce qui prend plus de temps d'exécution.

Ces chiffres sont ensuite utilisés en collaboration avec les poids des particules afin de sélectionner des particules x_k^* et de leur attribuer un facteur de duplication.

La sélection se fait suivant la distribution multinomiale suivante : $x_k^* = x(F^{-1}(u_k)) = x_i$ sachant que l'indice i est sélectionné sous condition d'intervalle $u_k \in \left[\sum_{s=1}^{i-1} w_s, \sum_{s=1}^i w_s \right]$

F^{-1} désigne l'inverse généralisé du cumul de la distribution de probabilité des poids normalisés des particules.

Explicitement, nous allons calculer un tableau des poids cumulés des particules puis nous allons parcourir ce tableau dans le sens décroissant pour chaque chiffre u_k . Quand ce dernier se trouve dans l'intervalle entre deux cumul de poids consécutives $\left[\sum_{s=1}^{i-1} w_s, \sum_{s=1}^i w_s \right]$ l'indice i nous permet de mettre un +1 à la particule ayant le poids w_i . Une fois le tableau inversé des poids cumulé parcouru N fois (une fois pour chaque u_k), nous nous retrouvons avec des particules sélectionnées avec leurs facteurs de duplications respectifs. La somme de ces facteurs est égale à N .

— Le rééchantillonnage Systématique :

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

Ce rééchantillonnage commence par générer N chiffre dans l'ordre suivant la formulation $u_k = \frac{(k-1)+\tilde{u}}{N}$ avec $\tilde{u}_k \sim U[0, 1]$.

Ensuite le principe de sélection utilisant la distribution multinomiale est appliqué.

— Les critères de déclenchement de rééchantillonnage :

Le déclenchement du processus de rééchantillonnage est le plus souvent conditionné par un critère. Deux critères se distinguent dans la littérature : Le premier critère calcule le nombre de particules effectives N_{eff} suivant l'équation 4.19 [KLW94]. Le second critère calcule l'entropie du nuage de particules en faisant l'analogie entre le nuage de particule et celui d'un gaz. L'entropie est calculée au sens de Boltzmann et Shannon dans la formulation introduite par Pham [Pha01] qui est la suivante :

$$S_k = - \sum_{i=1}^N u_k^i \ln(u_k^i) \quad (4.18)$$

Lorsque le nuage est efficace du point de vue des observations (pondérations) $S_k = \ln(N)$ et dans le cas contraire $S_k = 0$. Il faut ainsi fixer, dans cet intervalle pour S_k , un seuil S_{th} en dessous duquel un rééchantillonnage devra être opéré.

Pour notre application nous conditionnons notre rééchantillonnage avec le critère de Kong représenté par la relation suivante :

$$N_{eff} = \frac{1}{\sum_{j=1}^N (w_k^j)^2} \quad (4.19)$$

où w_k^i est le poids normalisé de la particule i à l'itération k .

Lorsque toutes les particules sont efficaces, leurs poids normalisés avoisinent $1/N$ ce qui donne $N_{eff} \rightarrow N$. Lorsque le nuage de particule n'est pas efficace, le poids a tendance à se concentrer dans une particule dont le poids avoisinera 1, alors $N_{eff} \rightarrow 1$. Ce critère est donc en relation directe avec le nombre de particules. En se référant aux deux cas limites de ce critère, il suffit de fixer un seuil dans l'intervalle du critère correspondant au nombre de particules efficace minimum à assurer. Le rééchantillonnage sera alors effectué lorsque N_{eff} est en dessous d'un seuil prédéfini par l'utilisateur : N_{th} . Ce seuil N_{th} est généralement une valeur constante $0 < N_{th} \leq N$: ex. $N_{th} = \frac{3}{4}N$ où N est le nombre de particules.

Après l'étape de rééchantillonnage, tous les poids des particules sont ensuite remis à $W_k^i = \frac{1}{N}$ ou recalculés par la distribution du poids de chaque particule sur le nombre de ces duplications.

4.3.4 Application du PF à la localisation des véhicules routiers

L'application du filtrage particulaire à la localisation des véhicules passe par les étapes décrites auparavant et résumées dans l'algorithme 1 pour une adaptation à la localisation multi-capteurs.

Comme l'algorithme 1 l'indique, notre application commence par l'initialisation du filtre particulaire. Bien entendu, l'utilisateur aura auparavant fixé le nombre de particules, les différentes variances si nécessaire et le seuil de rééchantillonnage. Les particules commencent par être distribuées en nuage gaussien initial autour de la position initiale connue. Les données issues de capteurs proprioceptives sont beaucoup plus fréquentes que celles issues de sources correctives dans notre cas le GPS. Le traitement se fait par type de source, une fois les données proprioceptives reçues, le filtre fait de la localisation à l'estime. Ceci consiste à démarrer du dernier point connu avec son incertitude, faire évoluer les particules en faisant usage des données reçues appliquées dans un modèle d'évolution, dans notre cas le modèle bicyclette détaillé en 3.2.2. Afin que le nuage de particule n'évolue pas en un bloc suivant la trajectoire obtenue par ce modèle, les bruits de modélisation et de mesures inertielles sont pris en compte. L'intégration de ces bruits nous permet d'avoir une évolution différente pour chaque particule, ce qui va générer un mouvement non uniforme des particules. Ceci renforce l'exploration de l'espace de recherche et renforce la probabilité de couvrir le vrai état du véhicule. Cette étape de prédiction est la clé de la localisation inertielle temps réel, sans laquelle nous ne pourrions pas fournir une information de localisation plus fréquente que celle du GPS. Une fois la donnée GPS disponible, nous pouvons procéder à un échantillonnage de nos particules. Ceci nous permet de juger quelles sont les particules efficaces et celles qui commencent à diverger. Le rééchantillonnage vient par la suite rééquilibrer la distribution des particules en éliminant les particules divergentes et en dupliquant les particules efficaces. Un bon rééchantillonnage doit avoir un minimum d'impacts sur la distribution probabiliste globale du nuage de particules. C'est-à-dire que d'un point de vue quantitatif, une fois le rééchantillonnage terminé, l'incertitude formée par le nuage de particules autour de la dernière position connue ne doit pratiquement pas changer. Recalculer cette incertitude en utilisant l'équation 4.13 avec les nouvelles variables et/ou faire un affichage dynamique temps réel sous forme d'ellipse d'incertitude peut être un bon test de validation pour la méthode de rééchantillonnage.

Algorithme 1 : Algorithme du filtre particulaire appliqué à la localisation des véhicules

A l'instant $k = 0$ (X_0 et P_0 connus)

Initialisation()

Génération de la première population de particules :

N particules réparties aléatoirement autour de la position initiale avec

$$W_0^i = \frac{1}{N}.$$

while (*Donnée capteur disponible*) **do**

If(**Donnée proprio**)

Déplacer les particules dans l'espace d'état suivant les données et le modèle véhicule.

Conserver les $W_0^i = \frac{1}{N}$.

Calculer l'état prédit et son incertitude :

$$X_{Vehicule} = \sum_{i=1}^N X_{k|k-1}^i * \frac{1}{N}$$

$$P(X_{Vehicule}) = \sum_{i=1}^N w_k^i \left(X_{k|k-1}^i - X_{Vehicule} \right) \left(X_{k|k-1}^i - X_{Vehicule} \right)^T$$

If (**Donnée extero**)

Calculer/mettre à jour le poids de chaque particule :

$$w_k^i \propto w_{k-1}^i \cdot p(Y_k | X_{k|k-1}^i) = w_{k-1}^i \cdot \frac{1}{\sqrt{(2\pi)^{|R_k|}}} \exp\left\{-\frac{1}{2}(Y_k - \hat{Y}_k)^T [R_k]^{-1} (Y_k - \hat{Y}_k)\right\}.$$

Normaliser les poids $w_k^i = \frac{w_k^i}{\sum_{j=1}^N w_k^j}$.

Déterminer l'état estimé du système et son incertitude :

$$X_{Vehicule} = \sum_{i=1}^N X_{k|k-1}^i * w_k^i$$

$$P(X_{Vehicule}) = \sum_{i=1}^N w_k^i \left(X_{k|k-1}^i - X_{Vehicule} \right) \left(X_{k|k-1}^i - X_{Vehicule} \right)^T$$

Calculer l'indicateur de rééchantillonnage :

$$N_{eff} = \frac{1}{\sum_{j=1}^N (w_k^j)^2}$$

If ($N_{eff} \leq N_{th}$)

Procéder au rééchantillonnage des particules par la méthode choisie.

Redistribuer les poids aux nouvelles particules.

end

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

4.3.5 Avantages et limites du filtre à particules

Le filtre particulaire par son approche multi-hypothèse à la base de sa robustesse, s'avère plus robuste aux différents bruits que ce soit de données ou de modélisation. Il peut donc traiter des cas de fortes non linéarités et des cas de densités de probabilité non gaussiennes [ZIBPJ08] ce qui n'est pas assuré par un filtre de Kalman. Néanmoins, le PF nécessite un temps de calcul considérable et proportionnel aux nombre de particules. Sachant que la précision du PF dépend du nombre de particules employées, il est nécessaire de faire un compromis entre la précision et le temps de calcul sous contraintes des exigences temps réel du système et des ressources informatiques. Vu le caractère aléatoire employé par le PF dans toutes les étapes, il est nécessaire d'assurer un nombre suffisants de particules afin d'éviter une divergence.

4.3.6 Conclusion

L'utilisation du filtre à particule apporte des améliorations à la localisation dite mono-hypothèse. Cependant, les performances du PF restent liées à un compromis temps réel/puissance de calcul. Le point à retenir et à améliorer est celui que le filtre particulaire au contraire du filtre de Kalman ne procède à aucune correction, il se contente d'éliminer les particules qui ont tendance à s'éloigner. L'idée est donc d'apporter la possibilité que même les particules un peu éloignées mais non divergentes puissent apporter une information, puis être déplacées de façon à recoller à la dynamique du véhicule. Le Kalman particulaire qui consiste à doter chaque particule d'un filtre de Kalman est une solution intéressante. Cette solution existe et consiste à employer autant de filtre de Kalman que de particules. Une possibilité d'intégrer une interaction en essayant de garder les avantages du filtrage bayésien et particulaire tout en assurant une possibilité de correction et non seulement de sélection nous conduit vers l'étude des méthodes métaheuristiques. Le but final est de pouvoir produire une localisation hybride tenant ses points forts des approches présentées et faisant coopérer les particules entre elles.

Chapitre 5

Localisation hybride réactive-coopérative

Sommaire

5.1	Introduction	56
5.2	Position du problème	57
5.3	Objectifs	59
5.4	L'optimisation par Essaim de particules "PSO"	60
5.4.1	Introduction à la PSO	60
5.4.2	Algorithme de base	60
5.4.3	Objectif et principe de la PSO	60
5.4.4	Domaines d'applications	62
5.4.5	Paramétrage et variantes PSO	63
5.5	PSO pour la localisation des véhicules routiers	68
5.6	Le filtre particulaire à essaim de particules "SPF"	70
5.6.1	Introduction	70
5.6.2	Principe et algorithme	70
5.6.3	Application du SPF à la localisation des véhicules routiers	74
5.6.4	Avantages et inconvénients du filtre SPF	76
5.6.5	Conclusion	77
5.7	Le filtre de Kalman Optimisé à Essaim de Particules "OKPS"	78
5.7.1	Introduction	78
5.7.2	Objectifs	79

5.7.3	Formulation de l'approche	79
5.7.4	L'OKPS : Principe et Algorithme	80
5.7.5	Application de l'OKPS à la localisation des véhicules routiers	86
5.7.6	Avantages et limites de l'OKPS	88
5.7.7	Conclusion	88

5.1 Introduction

La localisation est une brique essentielle servant à l'automatisation d'un véhicule. L'information de position et d'orientation pour un véhicule routier doit être la plus fiable possible. La sécurité des passagers étant prioritaire, la localisation affecte directement les décisions prises par les systèmes automatiques d'aide à la conduite, qu'ils soient passifs ou actifs. Afin de garantir des actions toujours prévisibles et une sécurité des usagers, les méthodes indépendantes complètement à base d'intelligence artificielle ne sont pas conseillées dans les systèmes décisionnels, de part leur côté évolutif et imprévisible. Les méthodes métaheuristiques restent tout de même des méthodes interprétant l'intelligence de comportement sans toutefois être actives ou imprévisibles. Comme noté auparavant, les approches de filtrage récursif particulière sont des méthodes assez robustes et efficaces pour des applications de localisation. Les limites qu'on peut noter pour les approches du type PF sont : La dépendance des performances à la puissance de calcul et le fait qu'il n'existe pas vraiment de correction d'état prédit pour l'estimation mais juste un échantillonnage parmi les états prédits. Les approches bayésiennes telles que le filtre de Kalman Étendu et ses variantes se distinguent par leur simplicité algorithmique et leur faible complexité computationnelle. Cela justifie que les approches bayésiennes sont généralement les plus employées dans les domaines de filtrage, fusion et contrôle commande. Cette simplicité algorithmique, résultat de simplifications telles que la linéarisation par série de Taylor ont cependant d'autres impacts négatifs tels que la non gestion des cas de fortes non linéarité. Une approche hybride, vise à tirer profit des avantages des approches citées auparavant tout en incluant de nouveaux concepts apportant de nouvelles informations.

En faisant l'analogie avec le domaine de la localisation multi sources, cela pourrait être semblable à une fusion multicapteurs. Ici au lieu de fusionner simplement le meilleur des données capteurs que nous avons à disposition, nous souhaitons en plus faire fusionner le meilleur des approches existantes afin de retourner une estimation hybride qui serait robuste et plus précise. Les méthodes métaheuristiques telles que l'optimisation par essaim de particules ont la particularité de faire collaborer

les particules. Cette collaboration apporte une efficacité supplémentaire au groupe de particules, ce qui permet d'atteindre les objectifs en employant moins de particules par rapport au tirage de Monté Carlo classique. L'hybridation d'une méthode récursive de filtrage particulaire par une métaheuristique semble pouvoir combler certaines lacunes que nous avons rencontrées. Cela revient à doter les particules d'un filtrage classique par de nouvelles capacités. Des capacités de communications et d'interactions qui viendront apporter une richesse d'information supplémentaire. Cette hybridation va aussi apporter un nouveau comportement des particules qu'il faudra étudier et maîtriser.

L'hybridation par une méthode métaheuristique, initialement non conçue pour ce type de problématiques, peut sembler quelque peu problématique. Il faudra faire des adaptations afin de pouvoir utiliser une méthode métaheuristique dans une application de filtrage récursif temps réel avec une gestion spatiotemporelle de la problématique de localisation. L'adaptation de n'importe quelle méthode nécessite une étude approfondie de cette dernière, afin de maîtriser les différents paramètres et impacts de leurs adaptations.

5.2 Position du problème

Le défi de départ consiste à prendre un filtre PF et une métaheuristique afin de créer un nouveau filtre capable d'employer les concepts des deux approches tout en retournant le meilleur de chacune. La première difficulté consiste à éviter de recréer une méthode existante, ce qui nécessite une étude bibliographique des méthodes hybrides de localisation et pour d'autres applications (ex. détection de source d'odeur ou de fuite de gaz et détection de défaillance capteurs telle que les approche IMM¹).

Un des verrous scientifiques est de pouvoir employer une métaheuristique dans une application temps réel récursive de type filtrage/fusion de données multicapteurs. Les méthodes métaheuristicques ont été créées et améliorées au fil des années pour des problèmes purement d'optimisation. L'optimisation consiste à traiter le même problème en boucle jusqu'à atteindre un objectif final déterminé par un critère de minimisation ou de maximisation prédéfini. Ainsi, l'exploration peut être infinie et l'optimum trouvé peut tout à fait être un optimum local ou global.

Le travail global consiste à étudier le fondement théorique et surtout le principe de comportement des particules dans les métaheuristicques afin de trouver l'adaptation qui conviendrait à notre application. L'adaptation de la méthode métaheuristique doit être aussi compatible et complémentaire à la logique algorithmique des méthodes

1. IMM : Interaction Multi Modèles

de filtrages classiques généralement utilisées pour la fusion de données. Le travail final vise à faire une étude complète des principes et des fondements des différentes méthodes (filtrage et optimisation) envisagées afin de trouver les bonnes concordances qui permettent la création d'un algorithme décrivant une seule méthode hybride à la fois réactive et coopérative.

Afin de clarifier les objectifs de cette hybridation et d'en dresser les principes, nous proposons dans ce qui suit une description des trois principes de base inspirants cette méthode.

- Hybride : Une méthode mathématique est dite hybride lorsqu'elle est le résultat d'un mélange des parties de plusieurs méthodes (au moins deux) ou qu'elle résulte sur l'enchaînement de plusieurs de ces méthodes afin de produire un seul résultat. Le terme hybride est décrit en génétique comme un organisme composé d'éléments de différentes natures, cet organisme est issu du croisement d'autres organismes de différentes natures et présente un mélange des caractéristiques génétiques des organismes parents. Par analogie, une méthode mathématique hybride présente aussi les caractéristiques des fondements théoriques des méthodes sources. Ces caractéristiques héritées peuvent regrouper des avantages et des inconvénients, tout le travail consiste à conserver le maximum d'avantages et le minimum d'inconvénients.
- Réactive : Le terme de réactivité en matière de localisation s'inspire de la définition générale du nom "réactivité". La définition de la réactivité est : La capacité à produire une réaction face à un stimulus extérieur, elle est mesurée au délai de réaction à ce stimulus externe. La réactivité d'une méthode de localisation est par conséquent sa capacité à réagir aux différents aléas et perturbations tels que les bruits de mesures, les erreurs de modélisation et les perturbations temporaires causées par l'environnement autour du véhicule. La réactivité étant mesurée par le délai de réaction, les méthodes vont être jugées par leur rendu en positionnement par rapport à la vérité terrain suite à une perturbation. Le temps de référence fixant un seuil de réactivité n'existant pas, la comparaison se fera grâce à l'analyse des graphiques produits par les différentes méthodes dans la même situation. Suivant la définition de la réactivité, la méthode qui prendra le moins de temps à recouvrer un positionnement stable et de meilleure précision sera la plus réactive.
- Coopérative : La coopérativité dans le domaine des mathématiques et spécialement les métaheuristiques est inspiré du monde vivant tout comme pour le principe d'hybridation. La coopérativité dans le monde de la chimie est une propriété des molécules (ou protéines et enzymes pour la biologie) dans les liaisons de fixation des différents substrats qui ne sont pas indépendantes,

mais se renforcent mutuellement. La définition générale du mot coopérativité découle de ce principe naturel et dit qu'un élément coopératif est un élément qui participe volontiers à un effort commun. Dans le domaine de la localisation par méthodes à base de particules, la coopérativité réside dans le principe que les différentes particules n'évoluent pas de manière indépendante comme dans le PF mais échangent des informations et interagissent dans le but d'atteindre un objectif commun.

5.3 Objectifs

L'objectif principal est de produire en finalité une information de localisation robuste aux aléas du signal GPS (multi-trajets et occultation) et plus précise que les approches existantes essentiellement dans les cas de fortes non linéarité et de forts bruits de mesures et/ou de processus. Ces performances attendues et exigées seront essentielles pour la localisation d'un véhicule routier à forte dynamique et aux changements multiples et imprévisibles de dynamique. Les changements de dynamiques du véhicules sont considérés comme multiples et imprévisibles car il est face à un environnement continuellement changeant et à des imprévus tels que les obstacles sur la route.

Afin d'atteindre ces objectifs finaux de précision et robustesse, nous nous concentrons sur la correction des points négatifs des meilleures méthodes de l'état de l'art. L'idée est de pallier aux limites des méthodes existantes en faisant une fusion multi approches. Cela revient à créer un nouveau filtre capable d'être réactif et faisant fonction d'une coopération entre ces différents agents en combinant leurs avantages.

En premier lieu, le but est d'intégrer l'aspect coopératif au filtre à particule par l'intégration d'une adaptation des étapes d'évolutions des méthodes d'optimisation. Ceci a pour finalité de diminuer la dépendance des performances au nombre de particules, vu que les informations pourront être échangées entre les particules. Aussi, une évolution qui permet d'optimiser la distribution de l'essaim pourrait être considérée comme une correction suivant le critère d'optimisation employé qui dans ce cas doit être aussi un critère de localisation.

Un dernier objectif supplémentaire est de gagner en temps d'exécution en diminuant au maximum l'occurrence du rééchantillonnage qui n'aura la nécessité d'intervenir qu'en cas de brusque changement de dynamique puisque la distribution est optimisée à chaque cycle. Les résultats obtenus par une telle hybridation ouvriront forcément d'autres possibilités d'améliorations. Le but final est de valider une approche de filtrage réactive coopérative pour la localisation de véhicules routiers, ceci afin que cette approche puisse être la source d'information de localisation pour des

applications d'aides à la conduite. Cette approche est destinée à fournir un positionnement précis du véhicule dans un environnement urbain où le signal GPS peut souffrir d'occultation et de multi-trajets à cause des canyons urbains.

5.4 L'optimisation par Essaim de particules "PSO"²

5.4.1 Introduction à la PSO

L'optimisation par essaims particulaires (OEP ou PSO en anglais) est une méta-heuristique d'optimisation, inventée par Russel Eberhart (ingénieur en électricité) et James Kennedy (socio-psychologue) en 1995. Initialement conçue pour la simulation de comportements sociaux dans le milieu naturel des groupes d'animaux vivants en interaction tels que les bancs de poissons et les nuées d'oiseaux, La PSO est attribuée à Kennedy, Eberhart et Shi [KE95]. L'OEP a été ensuite amélioré et simplifié par ses créateurs puis il a été employé à des fins d'optimisation [ES01, SE98a, SHI99]. Le livre de Kennedy et Eberhart [KKE01] décrit de nombreux aspects philosophiques de l'OEP. Des études approfondies des méthodes de PSO et des études comparatives sont disponibles dans [XH04, LLZ⁺13, BVA07, CK02, RSC06, MdO07, PC10].

5.4.2 Algorithme de base

Comme le décrit l'algorithme 2, un processus de base de PSO commence par une initialisation dans laquelle les différents paramètres sont définis et la première génération de particules créée. Vient ensuite une phase de boucle où les particules vont continuellement évoluer et estimer leurs scores (Fitness) en essayant d'améliorer au maximum leur performance. L'évolution se fera suivant les équations d'évolution adoptées et le jugement à l'aide d'une fonction de fitness définie selon l'application et le résultat recherché. Le processus d'optimisation peut parfois être très long voire même infini pour des cas particuliers (mauvais paramétrage, scores inadaptés). Pour éviter cela il est donc très utile de fixer au départ un nombre d'itération maximum ou un critère de performance à atteindre.

5.4.3 Objectif et principe de la PSO

L'optimisation par Essaim de Particule repose sur un ensemble d'échantillons appelés particules initialement disposées de façon aléatoire et homogène dans l'espace

2. PSO : Particle Swarm Optimization

Algorithme 2 : PSO : Algorithme de base

Début

Initialisation()

Génération de la première population de particules : répartition aléatoire uniforme autour de la position initiale.

while (*le critère* d'arrêt n'est pas atteint*) **do**

Fitness()

 Evaluer le score de chaque particule suivant la fonction de fitness

Mise à jour()

 Suivant les scores, mettre à jour P_b et G_b

Évolution()

 Faire évoluer les particules suivant les équations d'évolution

Estimation()

 L'estimée est le G_b

end

Fin

* : *Un nombre d'itérations ou un score adéquat*

de recherche. Chaque particule se déplace dans l'espace de recherche et représente une solution potentielle au(x) problème(s) traité(s). Chaque particule est munie d'une mémoire qui lui permet savoir à chaque cycle quelle est sa meilleure solution parcourue. Une particule a également la capacité de communiquer avec ses informatrices (particules voisines connectées et communicantes entre elles), ce qui lui permet de savoir quelle est la meilleure performance réalisée par ses voisines. Utilisant cette information, chaque particule se déplace en combinant ensemble trois tendances ou comportements : La tendance à garder sa propre trajectoire (égoïste), la tendance conservatrice et la tendance sociale (Panurgisme). Pour la première, la particule a tendance à utiliser son inertie et par conséquent continuer à garder sa propre direction et sa dynamique d'évolution. En adoptant la deuxième tendance, la particule tend à revenir à sa dernière meilleure performance en cherchant à améliorer ces performances (son score) sans être informée des performances des autres. Pour la troisième, la particule a tendance à se déplacer vers la meilleure solution trouvée par son voisinage. La figure 5.1 montre le principe de mouvement d'une particule PSO illustrant les tendances employées durant le mécanisme de collaboration.

Une particule i à l'instant k est caractérisée par un ensemble d'attributs : Le premier attribut est son vecteur d'état \hat{x}_k^i représentant sa position dans l'espace de

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

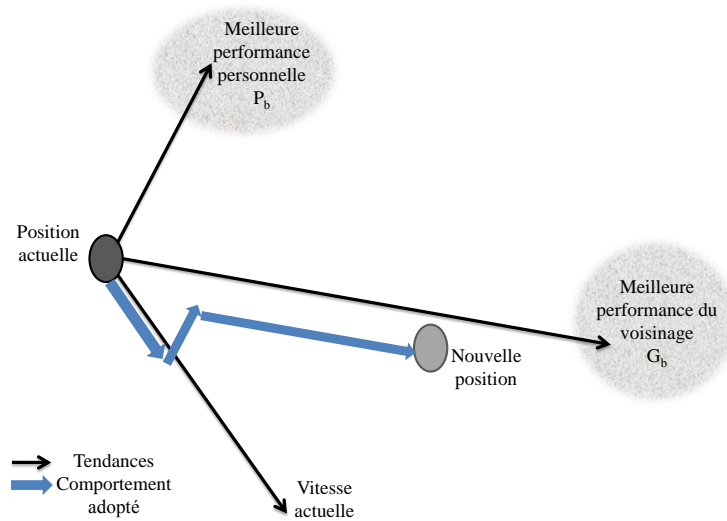


FIGURE 5.1 – PSO : Principe de déplacement d'une particule

recherche. Le second est l'information de déplacement \hat{v}_k^i qui est noté telle une vitesse par abus de langage mais correspond à une valeur de déplacement $\Delta\hat{x}_k^i$. Ensuite, le troisième attribut est un ensemble d'informations sur les performances. La première donnée de performance correspond à la meilleure solution trouvée par la particule elle même P_b^i (Personal Best). La seconde donnée de performance identifie la meilleure solution à l'itération k atteinte par les voisines G_b (Global Best). Le G_b est obtenu en comparant les différents P_b^i des particules voisines. A chaque nouvelle itération, la position de la particule i est mise à jour en utilisant les attributs qui ont été mentionnés précédemment en appliquant le principe de mouvement PSO décrit dans la figure 5.1. A partir d'optimums locaux, l'essaim de particules va normalement converger vers une solution optimale globale du système traité.

5.4.4 Domaines d'applications

Les problèmes généralement traités par la PSO sont l'optimisation des fonctions avec contraintes et le calcul d'optimum de fonctions non linéaires. Appliquée à notre problématique de localisation des véhicules, cette technique va se caractériser par des particules ayant comme *Position* un vecteur d'état de localisation, par exemple $\hat{x}_k^i = (x, y, \theta)^T$ et comme *Vitesse* un vecteur représentant l'évolution du vecteur d'état entre deux instants suivis ie. $\hat{v}_k^i = \Delta\hat{x}_k^i = (\Delta x, \Delta y, \Delta\theta)^T$.

Chaque particule avant de se déplacer va attribuer un *Score* à sa *Position* actuelle et en le comparant au meilleur score personnel qu'elle avait déjà sauvegardé ainsi qu'aux scores de ses voisins, cette particule pourra situer son P_b^i et le G_b (Best Global Position) qui représentent respectivement la meilleure position personnelle et globale ; Ensuite la particule évolue en combinant les trois tendances citées ci-dessus suivant les équations d'évolution.

La PSO est employée généralement pour des cas d'optimisation dit à environnement statique, pour lesquels le problème est connu et la solution ne change pas en cours d'optimisation, par exemple l'optimum d'une fonction avec contraintes. On peut employer la PSO pour des cas plus complexes dit à environnement dynamique où le système peut changer de comportement ou de configuration ainsi que l'optimum recherché. Il est aussi possible de faire de l'optimisation multi-objectifs qui consiste à chercher un ensemble de minimum locaux afin de satisfaire plusieurs contraintes à la fois. La multi-objectivité peut être aussi traduite par une solution recherchée qui fait la fusion de plusieurs objectifs.

5.4.5 Paramétrage et variantes PSO

5.4.5.1 Voisinage : Taille et topologie

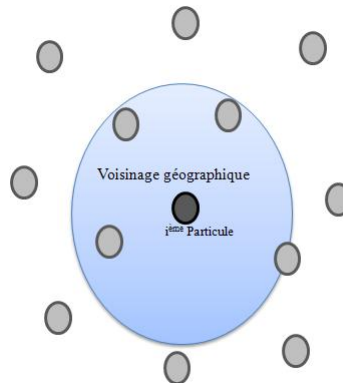


FIGURE 5.2 – Voisinage géographique




FIGURE 5.3 – Différentes configurations de voisinage social (de haut en bas et de gauche à droite) : En étoile, en anneau et en cercle.

Chaque particule communique et échange avec ses voisines et chaque particule est plus ou moins attirée par la meilleure solution dans son voisinage. Plus le voisinage est riche plus l'information est partagée, ce qui favorise fortement la convergence.

La PSO de base est facilement piégée dans un minimum local. Cette convergence prématurée peut être évitée en n'utilisant pas la meilleure position connue G_b de l'ensemble de l'essaim mais juste la position la plus efficace d'un sous-essaim "voisinage" de la particule qui se déplace. Un tel voisinage peut être géométrique ou, plus souvent, social. Le voisinage géométrique se base sur les positions des particules "les plus proches" et doit être recalculé à chaque itération, la figure 5.2 illustre ce voisinage. Quand au voisinage social, il ne nécessite aucun calcul. Il est défini en créant des relations prédéfinies de communications entre des particules dites voisines. Si l'on suppose qu'il existe un lien d'information entre chaque particule et ses voisines, l'ensemble de ces liens construit un graphique, un réseau de communication, qui est appelée la topologie de la variante PSO. Une topologie sociale couramment utilisée est l'anneau, mais il y en a beaucoup d'autres [Men04]. La topologie n'est pas nécessairement fixe, et peut être adaptative aussi (SPSO [Li04], stochastique étoiles [MKD08], TRIBUS [CCS09], Cyber Essaim [YGLZ11], C-PSO [EEB07]). La figure 5.3 montre quelques une des variantes les plus connues des topologies sociales de la

PSO.

5.4.5.2 Calibrage et choix des paramètres

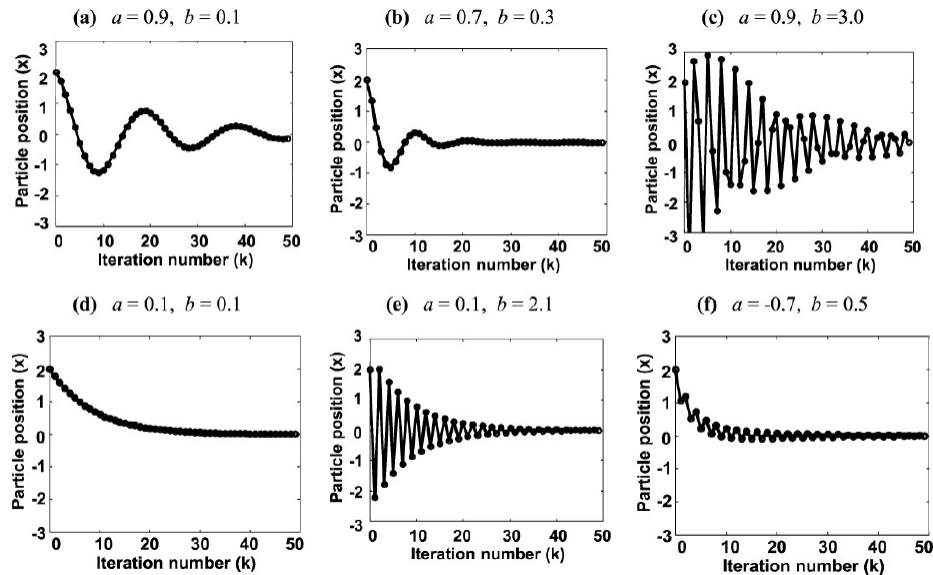


FIGURE 5.4 – Exemple de comportements suivant le paramétrage PSO

Le choix des paramètres de PSO peut avoir un grand impact sur les performances d'optimisation. La sélection des paramètres de PSO qui donnent de bonnes performances fait l'objet de nombreuses recherches [SE98b, ES00, Fra02, CD01, CK02, Tre03, BB08, abE09]. Les paramètres de PSO peuvent également être réglés en utilisant un autre optimiseur, un concept connu sous le nom de méta-optimisation [PC10, MSS06, Ped10]. Généralement, les paramètres à fixer sont : Le nombre de particules, la vitesse maximale d'une particule, le voisinage et les paramètres des fonctions d'évolution tel que le facteur d'inertie ou les coefficients d'apprentissage. Par exemple, dans les travaux suivants [Tre03] les auteurs présentent un paramétrage probabiliste purement expérimental de deux paramètres a et b . a et b représentent respectivement le facteur d'inertie et les facteurs d'influence sociale et personnelle fusionnés en un seul. La figure 5.4 montre les différents comportements de l'essaim suivant les valeurs expérimentales de a et b . Ce graphique montre que les particules, changent de comportement global suivant les valeurs fixées. De gauche à droite sur la figure 5.4, les particules vont adopter dans l'ordre un comportement convergent stable, un comportement oscillatoire en harmonique et qui finit par converger ainsi

qu'un comportement en zigzag avec une convergence aussi. La figure 5.4 montre les différents résultats de comportements obtenus pour différents paramétrages.

5.4.5.3 Évolution des particules en PSO

A chaque nouvelle itération la position de la particule est mise à jour à l'aide des équations d'évolution, la version basique de ces équations est la suivante [SE98a] :

$$\hat{x}_k^i = \hat{x}_{k-1}^i + \hat{v}_k^i \quad (5.1)$$

$$\hat{v}_k^i = \underbrace{W \hat{v}_{k-1}^i}_{\text{Inertie}} + \underbrace{c_1 r_1 (P_b^i - \hat{x}_{k-1}^i)}_{\text{Influence Personnelle}} + \underbrace{c_2 r_2 (G_b - \hat{x}_{k-1}^i)}_{\text{Influence Sociale}} \quad (5.2)$$

où r_1 et r_2 sont des nombres aléatoires tirés uniformément dans l'intervalle (0,1). c_1 et c_2 sont des facteurs d'apprentissages (coefficients de confiance) pour pondérer les tendances (conservatrice et panurgisme) et W le facteur d'inertie. Ces équations d'évolution sont inspirées par le comportement de groupe d'oiseaux, l'optimisation se fait par la coopération et la concurrence entre les individus. Chaque particule ajuste son évolution selon sa propre expérience et celle de ses compagnons.

Il existe plusieurs versions améliorées de ces équations. Chacune de ces variantes des équations d'évolution est conçue pour permettre d'avoir un équilibre entre la tendance à l'exploration et la tendance à converger vers une solution optimale. Parmi les variantes les plus connues notons la fonction d'évolution basée sur le facteur de constriction³ C (Cas particulier du coefficient d'inertie) proposée par Clerc & Kennedy [CK02] où la fonction de mise à jour de la vitesse est sous la forme suivante :

$$\hat{v}_k^i = C [\hat{v}_{k-1}^i + c_1 r_1 (P_b^i - \hat{x}_{k-1}^i) + c_2 r_2 (G_b - \hat{x}_{k-1}^i)] \quad (5.3)$$

Cette forme contraint les particules à évoluer dans un espace limité par ce facteur et les empêchent de trop se disperser en resserrant l'essaim de particules. C est le facteur de "constriction" de valeur fixe. Il améliore grandement les performances en termes de convergence et empêche strictement l'explosion de l'essaim en limitant

3. Constriction : Action d'exercer un resserrement par pression circulaire.

l'exploration à une zone prédéfinie. Ceci peut être négatif pour des applications où il faut être réactif et que le système change de comportement global pendant le cycle de fonctionnement.

Il existe d'autres variantes de fonctions d'évolutions qui font l'objet de travaux de recherches [BVA07, XH04, CK02, Fra02]. La plupart des approches utilisent une probabilité de distribution uniforme pour générer les nombres aléatoires (r_1 et r_2). Il est difficile d'obtenir un réglage fin avec une telle distribution et d'échapper aux minima locaux. Des travaux, proposent des mises à jour de vitesse sur la base d'une distribution gaussienne. Il a été prouvé dans ce cas, que les facteurs d'apprentissage c_1 et c_2 ne sont plus nécessaires et en utilisant l'OEP gaussienne, le facteur d'inertie W peut être mis à zéro et limiter la vitesse \hat{v}_k^i par une valeur maximale n'est plus nécessaire, cette variante décrite et validé dans [Kro04] est à l'origine de la variante d'évolution que nous utilisons et qui est la suivante :

$$\hat{x}_k^i = \hat{x}_{k-1}^i + \hat{v}_k^i$$

$$\hat{v}_k^i = W \hat{v}_{k-1}^i + |\text{randn}|(P_b^i - \hat{x}_{k-1}^i) + |\text{randn}|(G_b - \hat{x}_{k-1}^i) \quad (5.4)$$

Les seuls paramètres qui doivent être spécifiés par l'utilisateur sont donc le nombre de particules et le facteur d'inertie. Cette variante est adoptée afin d'assurer un minimum de paramétrage tout en garantissant la prise en charge des différents minima locaux ainsi que la prise en compte du comportement inertiel du véhicule.

Le facteur d'inertie, proposé par Shi et Eberhart [SE98a] est utilisé comme coefficient pour la première tendance comportementale d'une particule et représente une valeur critique que l'utilisateur calibre : Une valeur $\gg 1$ favorise l'exploration de l'espace de recherche alors qu'une valeur $\ll 1$ favorise une convergence prématurée. Généralement le facteur d'inertie est inclus dans $0 < W \leq 1$. [Fra02, XH04, SE98b, ES00] proposent des études comparatives des méthodes de choix des paramètres, des variantes d'évolution et du facteur d'inertie. Telle que la méthode qui consiste à prendre un facteur W dégressif au fil du processus d'optimisation. Le fait de fixer une valeur initiale et une valeur finale et de faire décroître régressivement le facteur d'inertie, nécessite une application statique où le système et son environnement ne changent pas en cours ainsi que le minimum ou maximum recherché.

5.4.5.4 Variantes d'évolution

De nombreuses variantes du même algorithme que la PSO de base sont possibles. Par exemple, il existe différentes façons d'initialiser les particules et leurs vitesses, amortir la vitesse, ne mettre à jour P_b^i et G_b qu'après que l'ensemble de l'essaim ait été mis à jour, etc. Certains de ces choix et leurs possibles impacts sur les performances ont été discutés dans la littérature [CD01]. Des variantes nouvelles et plus sophistiquées que la PSO sont également toujours en cours d'introduction dans une tentative pour améliorer les performances d'optimisation. Il y a certaines tendances dans la recherche ; l'une est de faire une méthode d'optimisation hybride utilisant PSO combinée avec d'autres optimiseurs [KL02, NA10]. Une des améliorations visées par la recherche est d'essayer d'éviter la convergence prématurée (introduire une stagnation), par exemple, en inversant ou en perturbant le mouvement des particules PSO [abE09, Xin10, LK02], une autre approche pour faire face à la convergence prématurée est l'utilisation de plusieurs essais (de l'optimisation multi-essaims) [Che13]. L'approche multi-essaim peut également être utilisée pour mettre en œuvre l'optimisation multi-objectifs. Enfin, il y a aussi des développements dans l'adaptabilité des paramètres de comportement de PSO lors de l'optimisation [ZZLC09, CCS09].

5.4.5.5 Fonction de Fitness et multi-objectivité

La fonction de Fitness est une fonction qui traduit un critère de minimisation ou de maximisation. Les particules se basent sur ce critère afin de juger leurs performances. C'est ce critère qui permet de générer les scores pour chaque particule, et éventuellement de définir la fin du processus d'optimisation avec un niveau de performance (niveau de Fitness) souhaité.

Une fonction de Fitness multiobjective est la somme de deux sous fonctions de fitness complémentaires : $F = F_1 + F_2$. Les deux fonctions ont pour objectif de maximiser la présence des particules au niveau de la région où la probabilité est élevée. Dans le cas d'une approche passant par les deux étapes de prédiction et de correction, la fonction de fitness peut faire un combiné de maximisation autour des régions à forte probabilité a posteriori et a priori. Ceci permettrait d'obtenir un bon compromis entre prédiction et correction afin de faire une estimation.

5.5 PSO pour la localisation des véhicules routiers

La PSO est faite essentiellement pour résoudre des problèmes d'optimisation et pas des problèmes en environnement dynamique. Appliquer la PSO à la localisation

temps réel d'un véhicule revient à l'adapter au filtrage. Il est donc nécessaire d'essayer de s'affranchir du principe d'interactivité au maximum et d'intégrer la dynamique de comportement du véhicule et la faire hériter aux particules.

Le Filtrage par multi essaims de particules (Multi Swarm Particle Filter) proposé par [HNT10] est une solution pour la localisation intérieure pour un robot mobile. L'idée s'approche de nos ambitions, cependant, dans cette approche l'auteur traite chaque position comme un cas d'optimisation à part. Sans dépendance temporelle (non Markovien), cette localisation ponctuelle est uniquement spatiale et nécessite l'utilisation de balises et/ou de cartographie (sans GPS). Aussi dans [GGLV12] l'idée et le principe appliqués restent une inspiration de la PSO afin de créer un processus d'égo-localisation. Ici, l'auteur s'appuie sur les données GPS et introduit une gestion des aspects aussi bien spatiaux que temporels en visant une application temps réel. Le problème de cette approche est qu'elle est dépendante d'une cartographie et de la précision de la carte, chose qui n'est pas toujours disponible. Aussi, le fait que la méthode utilise une pondération différente pour chaque source afin de les fusionner après est à double tranchant. Cette division des jugements permet de gérer chaque sources toute seule et permet d'avoir un système certes modulaire et facilement modulable (ajout de capteurs) mais fortement découplé. Les particules vont gérer chaque dimension de l'optimisation de façon à part ce qui va générer des sélectivités (biais) dans l'espace de recherche. Comme la PSO de base fonctionne dimension par dimension, la solution est plus facilement trouvée seulement quand elle se trouve sur un axe de l'espace de recherche, sur une diagonale, et encore plus facile si elle est au centre [MS05, Spe10]. Pour éviter ce biais, il est conseillé de faire des comparaisons équitables en utilisant des problèmes de référencement non-biaisés, qui sont décalés ou tournés [SHL⁺05].

Une autre solution consiste à modifier l'algorithme lui-même de sorte qu'il ne soit plus sensible au système de coordonnées [WKG07]. Nous proposons donc une adaptation de la PSO avec une gestion de l'aspect spatiotemporel (Markovien), en intégrant le processus d'évolution et de communication de la PSO à un filtre existant.

Cette approche est dédiée à la localisation temps réel de véhicules routiers avec de fortes dynamiques. Les sources de données seront des capteurs inertiels et un capteur GPS bas coût. La solution finale se concrétise par une hybridation du filtrage particulaire préalablement adapté à la problématique de localisation extérieur. La PSO apportera le côté coopératif visé afin d'améliorer les performances.

5.6 Le filtre particulaire à essaim de particules “SPF”⁴

5.6.1 Introduction

Ce filtre inspiré par l’hybridation du Filtre Particulaire avec une approche d’Optimisation Par Essaim de particules “OEP ou PSO” est sensé apporter la notion d’interactivité manquante au Filtre particulaire. Les particules, comme pour un Filtre Particulaire normal, passent par toutes les étapes nécessaires en plus d’une étape d’échange d’information et d’évolution de particules de façon communautaire. Après l’étape de pondération du PF, les particules échangent des informations (communiquer) et évoluent afin d’optimiser la répartition de l’essaim (se déplacer vers la région où les meilleures solutions (probabilités) sont trouvées). Se déplacement est conforme au concept de l’évolution de PSO. Cette hybridation par la PSO représente le coté coopératif qui n’existe pas nativement dans le filtre particulaire classique et qui vient s’ajouter à la capacité réactif du filtre. Cette intégration apporte un point qui corrige une des lacunes du PF. Comme noté dans la conclusion du filtre particulaire, les particules de ce dernier ne font pas vraiment de correction mais seulement de la sélection “échantillonnage”. L’estimation en PF se fait uniquement à l’aide des prédictions pondérées, voir équation 4.17. L’évolution PSO vient apporter une capacité de mouvement aux particules en cas de données extéroceptive, ce qui permet une vraie correction cette fois.

Dans la suite du document, les algorithmes et notations mathématiques du vecteur d’état du véhicule vont adopter deux sous notations représentant le même vecteur d’état. Représentatives de la position et orientation du véhicule $(X, Y \theta)^T$, La notation en petit \hat{x} sera employée lors des phases d’optimisations PSO et la notation en grand \hat{X} sera employée lors du filtrage et de la fusion afin de distinguer l’hybridation. La notation des poids des particules sera notée en minuscule w^i alors que le facteur d’inertie sera noté en majuscule W . Ces notations suivent au mieux les notations des approches sources afin de garder une cohérence dans les notations par rapport à la littérature tout en faisant ressortir le caractère hybride des nouvelles approches.

5.6.2 Principe et algorithme

Le Swarm Particle Filter suit toutes les étapes que le PF en appliquant les mêmes formules et les mêmes bruits afin d’avoir une base de comparaison semblable. La seule étape dans laquelle ce filtre se distingue du PF est l’étape de traitement de

4. SPF : Swarm Particle Filter

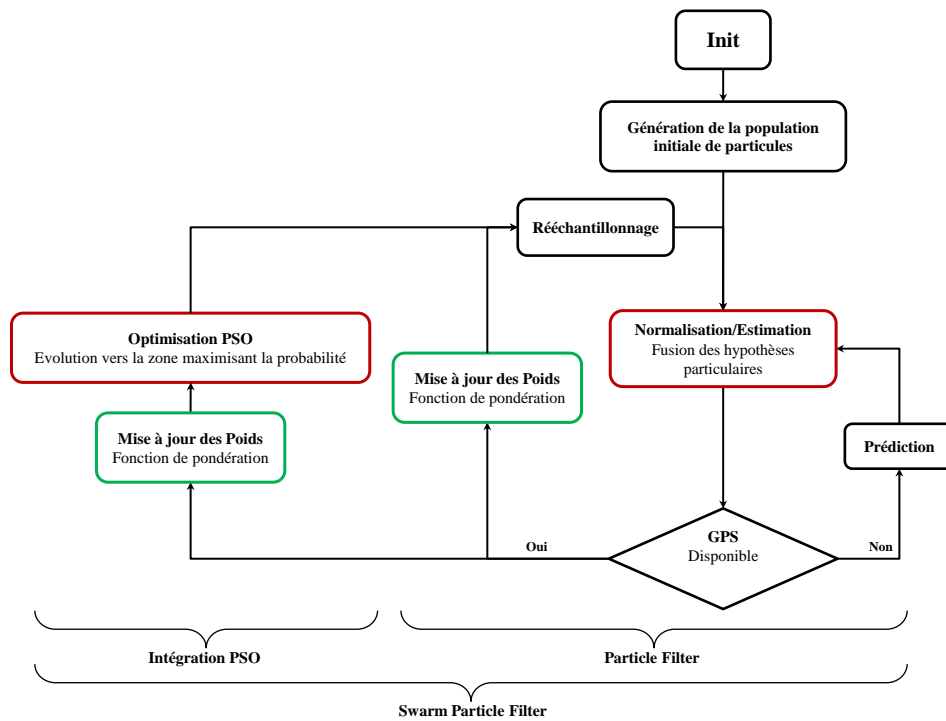


FIGURE 5.5 – SPF par hybridation PF/PSO

données extéroceptives où l'on vient ajouter une étape d'évolution des particules qui apporte l'aspect coopératif. L'intégration de cette étape nécessite l'hybridation des particules aussi en leur ajoutant les attributs PSO. Nous obtenons donc des particules enrichies (modifiées) qui ont tous les attributs d'une particule PF (ex. le poids w_k^i) et en complément les attributs PSO (ex. P_b^i et G_b) sans redondance pour les attributs communs aux deux approches tel que le vecteur d'état \hat{x}_k^i . La fonction de pondération jouera aussi le rôle de fonction de fitness. Les détails du déroulement de l'algorithme seront développés dans ce qui suit.

Le schéma algorithmique illustré par la figure 5.5 décrit l'hybridation du filtre particulaire par la PSO donnant l'algorithme général du filtre SPF.

Initialisation

Comme pour le filtre particulaire, le SPF commence par une étape d'initialisation dans laquelle il suit les mêmes fondements détaillées dans 4.3.3. En plus de créer et répartir la première génération de particules et leur attribuer des poids initiaux, le SPF les dote d'une capacité de communication en leur attribuant des voisins et en leur donnant accès à l'information du meilleur global G_b . L'initialisation concerne aussi la mise à zéro des vitesses d'évolution v_0^i , l'attribution d'une valeur au facteur d'inertie W et aux différents paramètres tel que le nombre de particules N et le seuil de rééchantillonnage souhaité N_{th} ou S_{th} selon le critère sélectionné. Nous discuterons du cas des meilleurs personnels P_b^i dans la phase d'évolution pour voir ce qu'il en advient.

Prédiction

Tout comme dans 4.3.3, l'étape de prédiction permet ensuite d'obtenir les prédictions particulières $\hat{X}_{k|k-1}^i$. Ces prédictions sont obtenues à partir des dernières positions connues des particules (X_0^i ou $\hat{X}_{k-1|k-1}^i$) et de leurs mouvements suivant les données proprioceptives appliquées au modèle bicyclette 3.2.2. Cette étape permet d'avoir un état prédit global en fusionnant les hypothèses de prédiction, ainsi que l'incertitude représentée par la répartition probabiliste a priori des particules.

Échantillonnage

En appliquant l'équation 4.15, chaque particule obtient un poids w_k^i (score), ce score sera ensuite normalisé suivant la procédure du PF afin d'être utilisé comme référence de performance pour l'évolution PSO.

Évolution

Après la normalisation des poids, l'évolution des particules se fait suivant les équations suivantes :

$$\hat{x}_{k|k}^i = \hat{x}_{k|k-1}^i + \hat{v}_k^i \quad (5.5)$$

$$\hat{v}_k^i = W \hat{v}_{k-1}^i + |randn|(G_b - \hat{x}_{k|k-1}^i) \quad (5.6)$$

Le G_b est sélectionné en comparant les poids des particules de l'essaim. Suivant l'équation 4.15, le G_b sera le vecteur d'état de la particule la plus proche de la donnée GPS.

Par rapport à l'équation 5.4, le terme $+|randn|(P_b^i - \hat{x}_{k|k-1}^i)$ a disparu dans cette variante d'évolution.

Dans la littérature [XH04, LLZ⁺13], les approches traitant des problèmes d'optimisation dynamique, éliminent la partie P_b^i des équations d'évolution PSO. Ce choix est appelé *l'effacement de mémoire*, P_b^i est donc constamment égale à la position actuelle de la particule $\hat{x}_{k|k-1}^i$, ce qui annule la partie concerné de l'équation 5.4 donnant l'équation 5.6. En considérant l'optimisation dans un environnement dynamique, le choix d'adopter l'effacement des mémoires des particules est tout à fait logique. Si la particule conserve ses performances alors que l'environnement ou le processus a changé, cela ne fera que la faire revenir à l'état précédent du système et/ou de son environnement. Le non effacement de mémoire pour des cas dynamique a pour conséquence de générer un retard permanent du filtre.

La variante d'évolution obtenue intègre donc deux concepts d'adaptation d'évolution, un premier de tendances gaussiennes aléatoires au lieu de facteurs d'apprentissage avec des nombres aléatoires uniformes. Et un deuxième d'effacement de mémoire pour pouvoir être conforme au traitement d'optimisation en environnement dynamique. Les deux concepts ont été étudié et validé dans [Kro04] et [XH04] respectivement. Ceci nous apporte l'avantage de réduire le nombre de paramètres qui doivent être fixés par rapport à la PSO de base.

Estimation

L'estimation consiste à faire fusionner les vecteurs d'états corrigés des particules afin d'obtenir un état estimé du véhicule et l'incertitude autour. Les calculs sont fait de la même manière que pour l'estimation du filtre particulaire, la différence ici est que les vecteurs employés sont des états corrigés (optimisés) et non des prédictions. Pour la formulation de la fusion, nous pouvons alors noter :

$$X_{Vehicule} = \sum_{i=1}^N \hat{X}_{k|k}^i w_k^i$$




FIGURE 5.6 – L'égo-localisation SPF

Rééchantillonnage

Vu que les particules passent par une étape de correction, elles sont censées optimiser leur distribution. Le processus de rééchantillonnage n'est conservé que pour garantir une certaine homogénéité de l'essaim, en évitant la concentration du poids dans une particule par exemple. Le protocole de rééchantillonnage ainsi que le critère employé sont détaillés dans 4.3.3.

5.6.3 Application du SPF à la localisation des véhicules routiers

Le SPF représente un premier pas vers une localisation réactive coopérative. L'implémentation de l'algorithme 3 et les tests ont nécessité des phases de calibrage, tests et réglages des différents paramètres tel que le nombre de particules et le facteur d'inertie. Les valeurs ont été sélectionnées après analyse de plusieurs tests dont la synthèse se trouve sous forme d'un tableau en annexe.

Après calibrage des paramètres de l'approche, les tests en application d'égo lo-

Algorithme 3 : Algorithme du filtre SPF appliqué à la localisation des véhicules

A l'instant $k = 0$ (X_0 et P_0 connus)

Initialisation()

Génération de la première population de particules :

N particules réparties aléatoirement autour de la position initiale avec

$W_0^i = \frac{1}{N}$ et $v_0^i = 0$.

while (*Donnée capteur disponible*) **do**

If(Donnée proprio)

Déplacer les particules dans l'espace d'état suivant les données et le modèle véhicule.

Conserver les $W_0^i = \frac{1}{N}$.

Calculer l'état prédit et son incertitude :

$$X_{Vehicule} = \sum_{i=1}^N X_{k|k-1}^i \cdot \frac{1}{N}$$

$$P(X_{Vehicule}) = \sum_{i=1}^N w_k^i \left(X_{k|k-1}^i - X_{Vehicule} \right) \left(X_{k|k-1}^i - X_{Vehicule} \right)^T$$

If (*Donnée extero*)

Calculer/mettre à jour le poids de chaque particule :

$$w_k^i \propto w_{k-1}^i \cdot p(Y_k | X_{k|k-1}^i) = w_{k-1}^i \cdot \frac{1}{\sqrt{(2\pi)^{|R_k|}}} \exp\left\{-\frac{1}{2}(Y_k - \hat{Y}_k)^T [R_k]^{-1} (Y_k - \hat{Y}_k)\right\}.$$

Normaliser les poids $w_k^i = \frac{w_k^i}{\sum_{j=1}^N w_k^j}$.

Déterminer G_b : meilleur poids normalisé

Évolution PSO :

$$\hat{v}_k^i = W \cdot \hat{v}_{k-1}^i + |randn| (G_b - \hat{x}_{k|k-1}^i)$$

$$\hat{x}_{k|k}^i = \hat{x}_{k|k-1}^i + \hat{v}_k^i$$

Déterminer l'état estimé du système et son incertitude :

$$X_{Vehicule} = \sum_{i=1}^N X_{k|k}^i \cdot w_k^i$$

$$P(X_{Vehicule}) = \sum_{i=1}^N w_k^i \left(X_{k|k}^i - X_{Vehicule} \right) \left(X_{k|k}^i - X_{Vehicule} \right)^T$$

Calculer l'indicateur de rééchantillonnage :

$$N_{eff} = \frac{1}{\sum_{j=1}^N (w_k^j)^2}$$

If ($N_{eff} \leq N_{th}$)

Procéder au rééchantillonnage des particules par la méthode choisie.

Redistribuer les poids aux nouvelles particules.

end

calisation restent prometteurs tout en faisant ressortir quelques limites. La figure 5.6 montre le rendu de l'approche SPF pour l'égo-localisation. Sur cette figure, on distingue en cercles cyan les données GPS, la plus proche étant la donnée actuellement traitée, elle est au centre de l'ellipse d'incertitude GPS. Les carrés noirs reliés entre eux sont des points de positionnement précis et qui servent de référence (vérité terrain). Les ellipses rouges et cyans représentent respectivement l'incertitude de positionnement et celle de la donnée GPS. Les carrés bleus et rouges ne sont que des projections (interpolation pour la bleu) pour pouvoir comparer le positionnement véhicule (rouge) avec la vérité terrain (bleu). Cette figure est issue d'un test rejoué avec des données réelles enregistrées sur les pistes de Satory à Versailles. Le plus remarquable dans ce test est que l'approche arrive à conserver des performances meilleures que le GPS malgré la concentration des particules et un risque de divergence.

La localisation avec le SPF s'avère réactive et efficace dans les cas où le véhicule garde la même dynamique pendant plusieurs cycles suivis (ligne droite ou grande courbe). Le problème visible sur l'image est que la distribution des particules néanmoins efficace semble être trop concentrée. En d'autres termes, le processus d'optimisation est assez efficace jusqu'au point de faire que l'essaim se concentre un peu trop vite lorsqu'il n'y a pas de grands changement de dynamique.

Ceci est négatif pour les cas tels qu'une longue ligne droite suivie d'un virage serré. Les particules auront tout le temps nécessaire pour bien se concentrer puis elles ne seront plus en mesure d'être efficace une fois le véhicule engagé dans le virage. Les tests montrent que ceci ne cause pas une divergence définitive du filtre. Cependant, le filtre fait de mauvaises estimations pour ces cas là et est sujet à des sorties de pistes (mauvaises estimations) puis recouvre la bonne trajectoire. Ceci s'explique par une trop grande concentration des particules, qui ne peuvent plus explorer plus largement l'environnement autour. Les particules n'ayant aucune voisine dans une position efficace, continuent par leurs inerties suivant la dernière dynamique connue pendant plusieurs cycles.

L'application du filtre SPF à la localisation des véhicules représente une bonne avancé mais soulève plusieurs nouvelles questions. Ces questions seront exposées à travers les inconvénients et avantages de l'approche. Des premières solutions seront discutées dans la conclusion pour essayer de répondre à ces questions.

5.6.4 Avantages et inconvénients du filtre SPF

Après avoir étudié l'approche SPF et les différentes influences et incidences des différents paramètres de cette approche et vu le caractère aléatoire de toutes les étapes, nous devons faire des tests stochastiques afin de choisir les paramètres adé-

quats faisant le compromis entre la restriction (facteur de rééchantillonnage) et la liberté (facteur d'inertie). La restriction permet d'éviter l'explosion de l'essaim et de garantir un certain niveau d'efficacité alors que la liberté permet d'avoir une richesse d'hypothèses qui est primordiale pour prévoir les changements de dynamique du véhicule. Les tests sont disponibles en annexe sous forme de tableaux résumant les impacts des différents facteurs 9.3.

L'inconvénient est que tout ce travail de calibration et de tests ne sera efficace que pour cette application de localisation et pour les mêmes types de capteurs ayant les mêmes gammes de bruits.

Néanmoins, cet aspect aléatoire apporté par la PSO n'a pas que des inconvénients car c'est l'élément principal qui permet de couvrir une plus large zone de l'espace d'état. Ceci a pour effet de garantir la présence d'une hypothèse se rapprochant du véritable état du véhicule, ce qui diminue le risque de divergence et augmente la robustesse.

Le caractère cognitif des particules permet aussi d'apporter une richesse d'information qui remplace l'ajout de capteurs supplémentaires. L'optimisation vient ensuite parfaire l'ensemble afin de tirer le meilleur de ces informations échangées. L'optimisation en elle-même, comme vu précédemment, est un concept assez simple à comprendre, implémenter et employer. Cependant, l'optimisation et plus précisément l'évolution apporte de nouvelles notions qui changent notre vision sur ce processus de localisation. Plusieurs questions se posent alors, essentiellement sur l'organisation algorithmique et non sur les paramètres. Par exemple, après l'étape de mise à jour et estimation, les poids des particules représentent l'efficacité à ce moment là. A l'étape suivante de prédiction qui n'est généralement pas trop éloigné d'un point de vue temporel, faudra-t-il garder les anciens poids ou employer de nouveaux poids homogènes sachant que les particules ne sont pas vraiment à égales performances.

Aussi une question qui s'est posée au cours du développement du SPF était : Pour la fusion, faut-il faire une moyenne pondérée à la manière du filtre particulaire ou opter pour le meilleur global G_b et le considérer comme la position du véhicule généralisée. L'approche SPF par ces questions et par des problèmes tels que la convergence prématurée reste une approche sur laquelle les travaux sont intéressants et nécessaires.

5.6.5 Conclusion

Afin de répondre aux questions soulevées, des tests ont été faits. Après tests ; Nous constatons que garder les anciens poids des particules donne de meilleurs résultats (moins de sauts) et ceci s'explique par le fait que le véhicule ne change pas radi-

calement de dynamique entre un cycle et le suivant, idem pour les particules qui, avec les poids du cycle passé et la prédiction du cycle actuel, donnent une estimation de l'état du véhicule. Une fois que les objectifs de précision sont atteints sous conditions de fonctionnement en temps réel, une comparaison avec une ou plusieurs autres approches s'impose.

Les améliorations à apporter sont nombreuses mais restent accessibles, comme l'utilisation d'une fonction de Fitness multiobjective [HNT10, RSC06, CK02, EC03, XH04] qui aurait pour but de satisfaire plusieurs contraintes et de répondre à plusieurs critères simultanément. Les améliorations auront pour but essentiel de corriger les problèmes de convergence prématurée et d'améliorer la robustesse et la précision de la localisation. L'idée consiste à diminuer directement la dépendance des particules (de la localisation) à la donnée GPS. Cette dépendance se traduit par la fonction de fitness 4.15 dans laquelle le poids d'une particule ne dépend que de sa position par rapport à celle du GPS. Il faut donc trouver une solution (nouvelle fonction de Fitness multiobjective) qui permet aux particules de juger leurs performances individuelles par rapport à une référence autre que la donnée GPS.

Ceci revient à doter les particules d'une nouvelle capacité d'évaluation communautaire ou individuelle qui ensuite pourrait servir à enrichir les informations traitées. L'idée et le concept des ces améliorations appliquées au SPF donnent naissance à une nouvelle approche qui sera présentée dans ce qui suit.

5.7 Le filtre de Kalman Optimisé à Essaim de Particules "OKPS"⁵

5.7.1 Introduction

Le filtre OKPS est une évolution du filtre SPF. Ce filtre proposé intègre en plus de la notion d'interaction sociale du SPF un aspect cognitif aux particules utilisées. Le concept cognitif consiste à donner une certaine notion d'intelligence à ces particules. Cette notion se traduit par une capacité d'auto-diagnostic des particules de l'essaim. Des particules dotées d'auto-diagnostic peuvent désormais évaluer leurs performances en se référant à la donnée GPS et à leur propre référentiel. Cette nouvelle capacité est très utile dans les cas où les mesures GPS Y_k sont aberrantes et que leur mesure d'incertitude R_k ne permet pas de les identifier comme tel. La fonction d'auto-diagnostic dans ce cas, permet à chaque particule d'avoir une autre référence qui est son propre vecteur d'état. La particule a alors le choix et peut donc faire un

5. OKPS : Optimized Kalman Particle Swarm

compromis entre la mesure GPS et son état actuel pour l'optimisation. Pour intégrer cette nouvelle capacité d'auto-diagnostic, nous nous inspirons du filtre de Kalman et considérons donc chaque particule comme une mesure en lui attribuant une incertitude sous forme de matrice de variance covariance. Cette matrice d'incertitude élémentaire P_k^i nous permet de faire plus ou moins confiance à la particule ou à la mesure, suivant leurs incertitudes respectives. Une nouvelle fonction de fitness (fonction de pondération) adaptative-multiobjective est également développée pour permettre aux particules d'adapter le calcul de leurs poids compte tenu de cette nouvelle capacité. La matrice d'auto-diagnostic des particules est gérée et mise à jour suivant le concept de l'EKF. La notion de gain de Kalman est intégrée afin de permettre la mise à jour de P_k^i qui doit être la plus représentative possible de la probabilité de l'état de la particule i . Le rôle de la nouvelle fonction de fitness adaptative et multiobjective est de donner un poids pour chaque particule compte tenu de son rendement par rapport à la mesure GPS et relativement à la confiance (incertitude) attribuée par la particule à sa prédiction.

5.7.2 Objectifs

L'objectif principal de cette approche est d'améliorer les performances du SPF tout en corrigeant ses limites. Les améliorations apportées par l'OKPS ont aussi pour but d'apporter des solutions simples et efficaces aux questions qui ont vu le jour après la réalisation du filtre SPF. Du point de vue théorique et algorithmique, l'OKPS est censé conforter la convergence par l'intégration d'une vraisemblance corrigée linéairement par un EKF pour chaque particule. Cette correction, certes, ne sera pas appliquée directement au vecteur d'état à la manière du filtre de Kalman, mais aura un impact direct sur la génération des poids des particules. En conséquence, d'un point de vue applicatif, les nouveaux poids affecteront le choix de mouvements (évolution) des particules optimisant la distribution suivant un compromis : mesure/hypothèses. Ceci permet de corriger deux points négatifs constatés pour le filtre SPF et qui sont : la convergence prématurée et l'influence importante des données GPS (aberrantes ou pas) sur le mouvement des particules.

5.7.3 Formulation de l'approche

Pour accomplir une localisation basée sur l'optimisation et le filtrage permettant d'être à la fois réactif et coopératif, l'OKPS combine les avantages des techniques présentées précédemment.

L'aspect coopératif consiste en l'échange d'informations et l'interaction entre les

particules. Alors que l'aspect réactif ressort de la capacité de détection de changements dans la dynamique du véhicule. Cette capacité de détection est la conséquence directe de l'enrichissement des particules par un simple mécanisme d'auto-diagnostic.

L'idée d'auto-diagnostic est accomplie par l'attribution d'une matrice de probabilité P_k^i aux particules. Cette matrice (inspirée de la matrice d'incertitude de la méthode EKF) permet à chaque particule d'évaluer sa vraisemblance en associant une matrice de variance covariance à son vecteur d'état. Comme mentionné dans l'introduction de l'OKPS, La matrice P_k^i doit être aussi représentative que possible de l'incertitude de positionnement des particules. C'est la raison pour laquelle cette matrice est gérée (mise à jour à chaque étape) par un gain de Kalman K .

L'approche peut sembler s'apparenter à un Kalman particulière où chaque particule est un filtre de Kalman Étendu à part entière. Ici le principe de Kalman n'est employé que pour la gestion des vraisemblances et en aucun cas pour la correction d'états des particules. La correction appliquée est tout à fait innovante puisqu'elle est issue d'une optimisation PSO échantillonnée par la suite par le principe du filtrage particulière.

Appliquer la correction sur le principe de Kalman n'est pas conseillé pour les systèmes à fortes dynamiques et sujets aux bruits variables ainsi qu'aux fortes non linéarités. La cause principale se trouve dans l'équation de correction de Kalman noté dans 4.6 et 4.12. Cette correction est une simple correction linéaire entre le vecteur d'état prédit et l'observation de la mesure. Dans le cas où le véritable état du véhicule ne se trouve pas dans l'espace d'état couvert par la zone de linéarité entre la prédiction et l'observation, le filtre fait une estimation fautive et peut diverger.

L'OKPS peut être considéré comme une approche hybride SPF évoluée, aidée par un gain de Kalman afin de réévaluer la vraisemblance des particules utilisée dans une nouvelle fonction de fitness adaptative.

5.7.4 L'OKPS : Principe et Algorithme

L'OKPS, comme toute approche multi-hypothèses, commence par une initialisation des particules. L'initialisation se rapproche de celle du SPF en appliquant les principes du tirage de monte carlo et de la PSO combinés, l'OKPS intègre en plus une initialisation de la matrice de variance covariance d'auto-diagnostic inspirée du principe du filtrage de Kalman. La localisation est donc accomplie récursivement suivants les étapes principales de prédiction et de mise à jour intégrant les nouvelles caractéristiques des particules. Le changement principal se situe au niveau de l'étape de mise à jour.

L'algorithme de l'OKPS est décrit dans l'organigramme présenté par la figure 5.7,

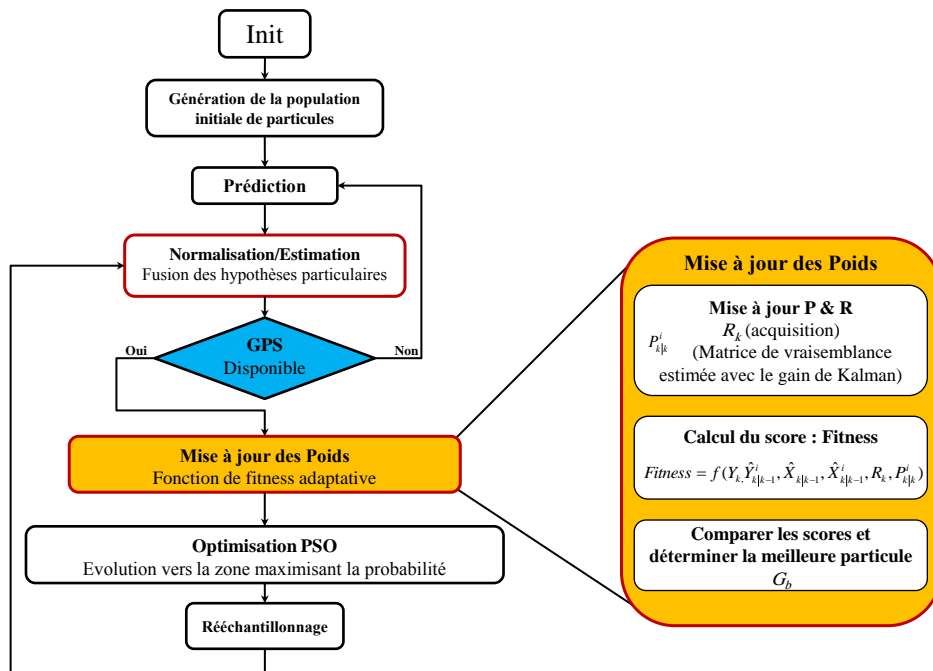


FIGURE 5.7 – Algorithme de l’OKPS

les détails de l'implémentation sont présentés dans ce qui suit :

Initialisation

L'initialisation de l'OKPS est effectuée de la même manière que pour l'initialisation du PF ou SPF du point de vue génération et distribution aléatoire autour de l'état initial connu ou choisi. Les détails des paramètres de la distribution suivant les différentes variances et écarts types sont notés dans 4.3.3. En supplément par rapport aux particules initiales du SPF, voir 5.6 ; Les particules de l'OKPS ont un attribut supplémentaire qui est la matrice P_k^i qui permet l'auto-diagnostic. Cette matrice est initialisée suivant le principe d'initialisation de la matrice de variance EKF noté dans l'équation 4.9. Les paramètres à fixer pour l'initialisation sont : Le nombre de particules N , le facteur d'inertie W et le seuil de rééchantillonnage N_{th} . Les données initiales recueillies sont utilisées pour définir la position initiale. Le calcul de \hat{X}_0 , P_0 , Q_0 et R_0 se fait à l'aide du jeu de données collectées initialement. Le calcul de ces valeurs initiales est décrit par le groupe d'équations 4.9.

Les attributs des particules de l'OKPS initialisés sont alors : $\vec{x}_i^{\rightarrow}(0)$ qui représente un vecteur d'état (vecteur de positionnement) tel que $x_{init} = (x_{init}, y_{init}, \theta_{init})^T$, $\vec{v}_i^{\rightarrow}(0) = 0$ représente la valeur initiale de la vitesse d'évolution des particules, $P_0^i = P_0$ est l'incertitude associée à l'état initial de chaque particule. La valeur de fitness (score, poids) de chaque particule est initialisée à $w_0^i = 1/N$. Cette valeur va être mise à jour pour chaque mesure GPS par la suite suivant l'équation de fitness adaptative 5.9. $G_b(0)$ représente le meilleur global parmi le voisinage et est obtenu par la comparaison des scores des particules. La valeur de G_b est aussi automatiquement mise à jour suite à l'acquisition d'une donnée GPS sans dépendance temporelle à la valeur précédente, ce qui permet de ne pas lui attribuer de valeur initiale.

Prédiction

Suivant la prédiction employée dans le PF et le SPF, les particules vont chacune prédire une possible position du véhicule $\hat{x}_{k|k-1}^i$. Cette prédiction se fait à l'aide du modèle bicyclette 3.2.2 dans lequel sont employées les données proprioceptives actuelles. Additionnellement à l'état prédit, une incertitude associée à cette prédiction est aussi calculée. Ce calcul fournit $P_{k|k-1}^i$ une valeur a priori de la vraisemblance d'une particule i et va représenter l'incertitude associée à son état prédit. $P_{k|k-1}^i$ est calculée suivant le principe de calcul de probabilité a priori du Filtre de Kalman Étendu noté dans l'équation 4.5. Cette dernière équation nécessite un calcul de Jacobienne. Ceci peut être considéré comme une limite dans d'autres applications mais dans le domaine de la modélisation automobile, il existe une multitude de modèles non linéaires simplifiés et dérivables. Le couple prédit constitué par l'état et son incertitude est le même que noté dans la prédiction de l'EKF dans l'ensemble

d'équations 4.11 :

$$\hat{X}_{k|k-1}^i = f(\hat{X}_{k-1|k-1}^i, U_{k-1})$$

$$P_{k|k-1}^i = A_{xk} P_{k-1|k-1}^i A_{xk}^T + Q_k$$

Un vecteur d'état global du positionnement prédit du véhicule $\hat{X}_{k|k-1}$ peut être alors déterminé par fusion des hypothèses en prédiction. La fusion se fait dans ce cas, selon la notation suivante :

$$\hat{X}_{k|k-1} = \sum_{i=1}^N \hat{X}_{k|k-1}^i w_k^i \quad (5.7)$$

Mise à jour

Cette étape consiste à actualiser les différentes variables intervenant dans le calcul des poids tel que les matrices d'incertitudes de prédictions et de mesure P et R . Nous obtenons alors des valeurs de probabilités a posteriori $P_{k|k}^i$ et R_k , mises à jour à l'aide du principe bayésien de Kalman et de l'acquisition de la mesure extéroceptive GPS.

Cette étape de mise à jour correspond à la mise à jour de P et R dans l'algorithme décrit dans la figure 5.7. Elle intervient avant la mise à jour des scores qui vient par la suite, l'étape de mise à jour des (poids) scores de l'algorithme OKPS est décrite comme un échantillonnage par la suite.

Avant d'évaluer les scores des particules, nous mettons à jour les matrices d'incertitude $P_{k|k-1}^i$ et R_k . La première matrice est mise à jour à l'aide d'un gain de Kalman. Cette méthode de Kalman a été adoptée pour la mise à jour des vraisemblances des particules car elle garantit une quasi-optimalité du minimum de variance a posteriori avec l'hypothèse d'un bruit gaussien. Ceci permet à la vraisemblance $P_{k|k}^i$ générée par l'équation 5.8 d'être la plus représentative possible de la probabilité de l'état de la particule i . La deuxième matrice R_k est la matrice d'incertitude de la mesure GPS, accessoirement elle permet de dessiner l'ellipse d'incertitude GPS. Cette matrice est mise à jour simplement par acquisition des données relatives à la qualité du signal GPS fournies par le capteur lui même. La mise à jour de $P_{k|k}^i$ est calculée par les expressions suivantes :

$$\begin{aligned} K_k^i &= P_{k|k-1}^i H_k^{iT} [H_k^i P_{k|k-1}^i H_k^{iT} + R_k]^{-1} \\ P_{k|k}^i &= (I - K_k^i H_k^i) P_{k|k-1}^i \end{aligned} \quad (5.8)$$

Échantillonnage

Cette étape d'échantillonnage consiste à déterminer parmi les particules, quels sont les échantillons à forte probabilité et quelles sont les particules qui peuvent être ignorées ou éliminées dans le cas actuel. Cette étape nommée échantillonnage pour la description correspond sur la figure 5.7 de l'algorithme OKPS à l'étape de mise à jour des scores. Le calcul se fait à l'aide de la nouvelle fonction de fitness définie pour cette application. Tout le comportement de l'essaim repose sur ce critère qui est la fonction de fitness.

Le score (poids) de chaque particule i correspond au résultat retourné par la fonction de fitness. Pour rappel, la fonction de fitness peut être un critère de maximisation ou de minimisation. Ce critère va représenter un but précis ou un compromis entre plusieurs buts. La sélection de cette fonction dépend de l'application et du résultat souhaité, pour plus de détails voir [EC03, RSC06, Fra02].

Dans l'OKPS, la fonction de fitness 5.9 est un critère de maximisation. Le calcul de chaque score prend en compte deux sources d'informations : La source extéroceptive GPS en positionnement absolue Y_k et la source d'hypothèse en prédiction de chaque particule $\hat{X}_{k|k-1}^i$, qui est un positionnement absolu en soit mais qui peut tout à fait être considéré comme relatif par rapport à l'ensemble de l'essaim et à sa prédiction fusionnée $\hat{X}_{k|k-1}$. Le compromis entre ces deux sources sera effectué par une moyenne pondérée en prenant en considération leurs erreurs quadratiques relativement à leurs incertitudes respectives.

$$w_k^i = \exp\left\{-\frac{1}{2}[(Y_k - \hat{Y}_k^i)^T [R_k]^{-1} (Y_k - \hat{Y}_k^i) + (\hat{X}_{k|k-1} - \hat{X}_{k|k-1}^i)^T [P_{k|k}^i]^{-1} (\hat{X}_{k|k-1} - \hat{X}_{k|k-1}^i)]\right\} \quad (5.9)$$

Sachant que : $\hat{Y}_k^i = H_k \hat{X}_{k|k-1}^i = (X, Y)^T$ est l'observation, $Y_k = (GPS_x, GPS_y)^T$ est la mesure GPS. R_k représente l'incertitude de la mesure GPS et $P_{k|k}^i$ l'incertitude de la particule i mise à jour. $\hat{X}_{k|k-1}$ est l'état du véhicule prédit. La normalisation des scores est une étape importante qu'il ne faut pas oublier, car c'est elle qui permet d'homogénéiser les scores afin de pouvoir les comparer. La normalisation est faite suivant l'équation 4.16. Le meilleur global G_b est ensuite déterminé par la comparaison des scores des particules, il sera le vecteur d'état prédit $\hat{x}_{k|k-1}^i$ de la particule ayant le score le plus important.

Évolution

Dans cette étape, chaque particule va pouvoir optimiser son estimation en évoluant dans l'espace d'état. Cette évolution est accomplie suivant les équations 5.5 et 5.6. Cette variante est obtenue en appliquant le principe de PSO gaussienne proposé

et validé par [Kro04], tout en l'adaptant à l'optimisation en environnement dynamique par effacement de mémoire exposée dans [XH04]. Les particules vont alors faire coopérer la tendance d'inertie et celle qui favorise l'attraction au G_b dans le but d'évoluer vers la zone d'intérêt du point de vue fitness.

Les particules vont avoir chacune un nouveau vecteur d'état $\hat{x}_{k|k}^i$ désormais dit a posteriori. Le résultat est une nouvelle distribution de l'essaim, optimisée et concentrée vers la région maximisant les valeurs de fitness. La nouvelle notion de fitness adaptative et multiobjective par rapport à celle employée dans le PF et SPF est la contribution qui change le comportement évolutif de l'essaim. Le bénéfice principal de l'équation 5.9 par rapport à l'équation 4.15 est que le G_b et les scores ont désormais une nouvelle définition adaptative.

Au lieu de pondérer les particules seulement par rapport à leur position à celle du GPS, comme dans le SPF ; la fonction de fitness de l'OKPS permet de considérer l'inertie des particules pour leur pondération en évitant la dépendance aux données GPS. Cette évolution adaptative rend le filtre plus robuste aux valeurs aberrantes du capteur GPS.

Estimation

Les résultats des particules après évolution sont fusionnés afin d'avoir une nouvelle estimation de l'égo-localisation du véhicule $\hat{X}_{k|k}$. Les estimations des particules $\hat{X}_{k|k}^i$ sont fusionnées en utilisant les poids normalisés qui sont les mises à jour des scores de fitness normalisés. La fusion de l'estimation globale est réalisée avec l'équation suivante :

$$\hat{X}_{k|k} = \sum_{i=1}^N \hat{X}_{k|k}^i w_k^i$$

Rééchantillonnage

L'algorithme de ré-échantillonnage et son critère de déclenchement sont les mêmes que ceux utilisés pour le PF et SPF, l'algorithme choisi est celui du rééchantillonnage systématique et le critère est le nombre de particules efficaces de Kong et Liu.

Dans les mêmes conditions, avec le même seuil de rééchantillonnage N_{th} et les mêmes données traitées, le déclenchement du rééchantillonnage se produit pour l'OKPS à une occurrence moins importante que pour le PF ou le SPF en raison de l'optimisation adaptative qui rend les particules plus réactives et augmente par conséquent le nombre de particules efficaces. Le processus de rééchantillonnage est encore un processus de calcul lourd, et éviter des rééchantillonnages parfois inutiles est avantageux. En outre, moins la population de particules est rééchantillonnée plus les caractéristiques dynamiques d'estimation sont préservées.

5.7.5 Application de l'OKPS à la localisation des véhicules routiers

Comme décrit précédemment, l'OKPS est un filtre récursif multi-hypothèses visant à proposer une version améliorée de filtrage optimisé pour la localisation des véhicules routiers. L'OKPS fait usage des avantages des approches appliquées à la localisation, présentées dans l'état de l'art. Le déroulement de l'algorithme de l'OKPS est détaillé dans l'algorithme 4. Tout comme pour un filtrage bayésien classique, l'OKPS passe par les étapes de prédiction et de correction récursivement et respectivement suivant la réception des données proprioceptives et extéroceptives. La localisation commence par l'initialisation autour de l'état initial du véhicule. Cet état est déterminé en faisant la moyenne de plusieurs données collectées pour un état stationnaire du véhicule. Une fois l'essaim de particules initialisé autour de cet état suivant les incertitudes associées, les étapes de prédiction et de correction s'enchaînent alors le long du scénario de localisation jusqu'à arrêt du flux de données.

L'étape de prédiction de l'OKPS se distingue par rapport à celle du SPF seulement par la matrice de probabilité individuelle attribuée à chaque particule. Comme noté dans le descriptif précédent et dans l'algorithme 4, la valeur prédite de cette matrice est calculée suivant le principe du filtre de Kalman. Vient par la suite l'étape de correction dans laquelle l'OKPS se distingue bien des autres approches existantes. Ici, l'OKPS procède, après acquisition de la donnée GPS $Y_k = (GPS_x, GPS_y)^T$ et de son incertitude R_k , à la mise à jour des matrices de probabilité des particules toujours suivant le principe de filtrage du Kalman étendu.

Les scores des particules sont calculés par la suite en faisant un compromis entre la prédiction et la correction. Ce nouveau calcul de fitness est la clé de fonctionnement de l'OKPS est c'est la finalité recherchée par l'ajout de cette capacité d'auto-diagnostic. Effectivement, l'effet de la nouvelle définition des scores est directement visible sur le comportement des particules dans l'étape d'évolution. Chaque particule mélange dans sa pondération un jugement par rapport au GPS et un autre par rapport à l'incertitude de cette particule vis-à-vis de la solution globale de l'essaim. Ceci a pour effet de permettre à la particule de ne pas être trop influencée par les données GPS aberrantes, puisqu'elle a en parallèle son propre référentiel interne dans l'espace fabriqué par ces voisines.

L'OKPS fait donc ce mélange de coopérativité et de réactivité qui permet une localisation robuste et précise. L'OKPS est plutôt destiné à la localisation en milieu urbain où les erreurs et les masquages GPS sont les plus fréquents.

Algorithme 4 : Algorithme du filtre OKPS appliqué à la localisation des véhicules

A l'instant $k = 0$ (X_0 et P_0 connus)

Initialisation()

Génération de la première population de particules :

N particules réparties aléatoirement autour de la position initiale :

$$W_0^i = \frac{1}{N}$$

$$v_0^i = 0$$

$$P_0^i = P_0 = E[(X_0 - \hat{X}_0)(X_0 - \hat{X}_0)^T]$$

while (*Donnée capteur disponible*) **do**

If(Donnée proprio)

Déplacer les particules dans l'espace d'état suivant les données et le modèle véhicule.

$$\hat{x}_{k|k-1}^i = f(\hat{x}_{k-1|k-1}^i, U_{k-1})$$

$$P_{k|k-1}^i = A_{xk} P_{k-1|k-1}^i A_{xk}^T + Q_k$$

Conserver les $W_0^i = \frac{1}{N}$.

Calculer l'état prédit du système et son incertitude :

$$\hat{X}_{k|k-1} = \sum_{i=1}^N \hat{x}_{k|k-1}^i \cdot w_k^i$$

$$P(\hat{X}_{k|k-1}) = \sum_{i=1}^N w_k^i \left(X_{k|k-1}^i - \hat{X}_{k|k-1} \right) \left(X_{k|k-1}^i - \hat{X}_{k|k-1} \right)^T$$

If (**Donnée extero**)

Calculer/mettre à jour les incertitudes de la mesure et des particules :

R_k par acquisition

$$K_k^i = P_{k|k-1}^i H_k^{iT} [H_k^i P_{k|k-1}^i H_k^{iT} + R_k]^{-1}$$

$$P_{k|k}^i = (I - K_k^i H_k^i) P_{k|k-1}^i$$

Calculer/mettre à jour le poids de chaque particule :

$$w_k^i = \exp\left\{-\frac{1}{2}[(Y_k - \hat{Y}_k^i)^T [R_k]^{-1} (Y_k - \hat{Y}_k^i) + (\hat{X}_{k|k-1} - \hat{X}_{k|k-1}^i)^T [P_{k|k-1}^i]^{-1} (\hat{X}_{k|k-1} - \hat{X}_{k|k-1}^i)]\right\}$$

Normaliser les poids $w_k^i = \frac{w_k^i}{\sum_{j=1}^N w_k^j}$.

Déterminer G_b : meilleur poids normalisé

Évolution PSO :

$$\hat{v}_k^i = W \cdot \hat{v}_{k-1}^i + |\text{randn}| (G_b - \hat{x}_{k|k-1}^i)$$

$$\hat{x}_{k|k}^i = \hat{x}_{k|k-1}^i + \hat{v}_k^i$$

Déterminer l'état estimé du système et son incertitude :

$$\hat{X}_{k|k-1} = \sum_{i=1}^N X_{k|k}^i \cdot w_k^i$$

$$P(\hat{X}_{k|k-1}) = \sum_{i=1}^N w_k^i \left(X_{k|k}^i - \hat{X}_{k|k-1} \right) \left(X_{k|k}^i - \hat{X}_{k|k-1} \right)^T$$

Calculer l'indicateur de rééchantillonnage :

$$N_{eff} = \frac{1}{\sum_{j=1}^N (w_k^j)^2}$$

If ($N_{eff} \leq N_{th}$)

Procéder au rééchantillonnage des particules par la méthode choisie.

Redistribuer les poids aux nouvelles particules.

end

5.7.6 Avantages et limites de l'OKPS

L'avantage principal de l'OKPS est la capacité d'auto-diagnostic de ces particules. Pratiquement cette capacité génère l'avantage de minimiser la dépendance des particules aux données GPS. Cette minimisation de dépendance reste toutefois conditionnée par les incertitudes respectives des particules vis-à-vis de celle de la donnée GPS. Le poids de la particule aura pour rôle de la faire pencher plus ou moins vers la source ayant la plus grande probabilité.

L'OKPS n'est pas censé consommer plus de ressources en matière de calcul que le filtre particulaire, car il s'est avéré que les particules deviennent plus efficaces et n'ont pas besoin d'être rééchantillonnées aussi fréquemment que dans le PF et le SPF. Cette approche répond aussi à quelques interrogations suite à l'application du SPF, tel que la convergence prématurée.

Le filtre OKPS censé tirer que les avantages, conserve paradoxalement quelques limites des approches desquelles il s'inspire. L'intégration de la matrice d'auto-diagnostic gérée par le filtre de Kalman est limitée par la dérivabilité du modèle d'évolution en jacobienne. Les particules gagnent en confiance lorsque la dynamique du véhicule ne change pas pendant plusieurs cycles suivi et ont tendance à négliger un peu les données GPS qui arrivent par la suite, si ces dernières annoncent un trop brusque changement de dynamique. Cependant, comme expliqué précédemment, cette indépendance vis-à-vis des données GPS est théoriquement relative à leur incertitude.

5.7.7 Conclusion

Le filtre OKPS représente finalement une solution aux limitations du SPF. Le filtre constitue alors une approche réactive-coopérative pour une égo-localisation de véhicules routiers en milieu urbain dans des conditions dégradées.

La capacité d'auto-diagnostic des particules apporte un réel avantage à leur comportement. Les paramètres à fixer sont moins nombreux que pour les approches d'optimisation classiques ou les approches de localisation hybride multi-hypothèses. Il reste tout de même à tester les performances de ce filtre dans plusieurs cas de figure afin d'en étudier les limites expérimentales ainsi que pour voir s'il peut s'adapter à plusieurs cas de localisation malgré le faible nombre de paramètres de calibrage. L'OKPS est sensé faire preuve de réactivité en cas de changement de dynamique, mais aussi de robustesse aux erreurs si les mesures annoncent des changements de dynamiques aberrants.

Les performances de l'OKPS doivent être comparées aux autres approches. Afin d'avoir une comparaison équitable, les différents filtres vont être testés dans les mêmes

conditions avec les mêmes paramètres. La question qui peut se poser à ce stade est au sujet des critères de comparaison et validation.

L'OKPS étant une approche hybride fusionnant plusieurs types d'approches destinées à plusieurs applications différentes et souvent testées suivant des critères très différents, doit avoir de nouveaux critères. Ces critères doivent être adaptés à l'approche, à ces concurrentes et à la problématique étudiée qui est l'égo-localisation de véhicules routiers. L'étude et le développement de nouveaux critères adaptés à cet effet ainsi que les tests dans plusieurs cas de figures seront présentés et analysés dans la partie suivante.

Chapitre 6

Protocole de test et de validation des estimateurs

Sommaire

6.1	Introduction	90
6.2	Performances d'un estimateur	92
6.2.1	Critères de précision	94
6.2.2	Consistance et crédibilité d'un estimateur	99
6.2.3	La robustesse	106

6.1 Introduction

Comme nous l'avons montré dans les premiers chapitres de ce document, il existe plusieurs méthodes et solutions pour la problématique de localisation extérieure à forte dynamique destiné aux applications de transports routiers. La plupart de ces méthodes sont basées uniquement sur des systèmes de radionavigation grâce à des constellations de satellites GNSS (Global Navigation Satellite System). Ce type de systèmes fournit une localisation absolue dite partiellement intègre. La localisation GPS fonctionne correctement en milieu ouvert assurant une bonne visibilité de quatre satellites au minimum et avec une bonne répartition spatiale. Outre ces conditions, le GPS peut fournir des mesures aberrantes. Le GPS peut éventuellement être impacté par le masquage de son signal par l'environnement comme le montre la figure 3.1 en illustrant l'exemple du canyon urbain. Il peut aussi générer de fausses mesures à cause des réflexions du signal sur les parois des hautes infrastructures urbaines. Il

s'avère indispensable de compenser ces masquages et aberrations. La solution est l'hybridation des informations de radio-localisation satellitaire par d'autres informations supplémentaires ne souffrant pas des mêmes phénomènes. Ces nouvelles informations ne doivent pas être directement liées à l'environnement du véhicule et doivent être capable de donner une idée sur la dynamique du véhicule afin de le localiser. La localisation avec ces nouvelles sources doit être complémentaire au GPS et capable de prendre le relais pendant la perte du signal GPS. Les capteurs les plus appropriés à satisfaire ces exigences fonctionnelles sont des capteurs proprioceptifs : odomètre, gyroscope, codeur d'angle de braquage, compas, accéléromètre, etc. La "Fusion de données" fait collaborer ces capteurs avec le GPS pour une égo-localisation robuste du véhicule.

Les chapitres précédents présentent l'état de l'art des méthodes les plus utilisés en matière de fusion de données pour des applications de localisation extérieure à forte dynamique. La fusion de données vise à utiliser les données issues du capteur extéroceptif et des proprioceptifs embarqués dans l'égo-véhicule. Ceci est accompli grâce à des estimateurs qui utilisent un modèle cinématique du véhicule ou une multitude de sous modèles du comportement du véhicule ou du système à étudier, comme dans [NGG07, BBS88, DLH98]. Le vecteur à estimer est alors un vecteur de localisation qui généralement est composé d'un ensemble des composantes selon la précision exigée et la complexité du modèle véhicule employé : position en X ou latitude, position en Y ou longitude, cap (orientation), vitesse longitudinale, vitesse latérale, vitesse angulaire autour de l'axe du lacet et les accélérations.

Les approches hybrides de fusions de données sont des approches récemment développées. De plus, chaque méthode hybride est un mélange ou une collaboration entre plusieurs méthodes ou modèles développés généralement pour d'autres problématiques. Les méthodes sources sur lesquelles se base une méthode hybride ont chacune des tests et des critères de performance bien précis dans leurs domaines de prédilection respectifs. Par exemple la PSO a dans plusieurs cas d'applications en optimisation des tests standardisés "Benchmarks" qui permettent de comparer les performances et suivant des critères bien définis pour chaque test. Ici, le problème réside dans la diversité des approches et dans la nature hybride de l'OKPS. Afin de tester et comparer les performances des approches en matière d'égo-localisation routière, faut-il utiliser des critères issus des fondements théoriques des approches afin de faire des tests fondés théoriquement ou faut-il plutôt faire des tests applicatifs afin de voir les performances réelles en localisation expérimentale ?

Les travaux de Ndjeng [NNLGG09, NGL⁺09, NGGL11] traitent en partie cette question et font une analyse des critères développés et étudiés. Nous allons donc commencé par faire un résumé de ces critères. A la suite d'une discussion et d'une

analyse de ces travaux, nous choisirons les critères les plus appropriés afin de les employer dans nos tests comparatifs.

6.2 Performances d'un estimateur

Les algorithmes d'estimation d'état sont largement utilisés en recherche et ingénierie. Nonobstant la solidité des fondements théoriques d'un estimateur, ses paramètres et performances sont généralement évalués en pratique. Les tests expérimentaux en plus de permettre un calibrage approprié des différents paramètres, permettent de valider l'approche et de la comparer avec d'autres méthodes pour la même application visée. Un estimateur est construit autour d'un ensemble d'hypothèses conditionnant son fondement théorique et par conséquent son fonctionnement. Les tests expérimentaux sont utiles pour l'utilisateur qui est intéressé par le bon fonctionnement dans l'application développée. Les performances d'un estimateur dépendent de la qualité des données et des différents bruits de processus et de mesures considérés. Afin d'aboutir à une comparaison objective et impartiale des performances des estimateurs pour une application d'égo-localisation, il est nécessaire de concevoir ou choisir une base de critères bien définie. Ces critères devront être adaptés à l'ensemble des techniques employées sans en favoriser une par rapport à l'autre, tout en étant adapté à l'application.

Dans [NN09] l'auteur développe un protocole de comparaison d'estimateurs bayésiens pour la localisation reposant sur trois familles de critères qui sont : la crédibilité, la précision et la robustesse.

- La crédibilité et la consistance d'un estimateur sont représentatives de sa capacité à traiter la problématique en respectant des gammes de variances d'erreurs acceptables pour l'application. Un estimateur crédible se doit de fournir une donnée d'incertitude autour de son estimé, c'est la valeur de cette incertitude qui va déterminer la crédibilité et la consistance de l'estimateur. L'estimateur ne doit pas être trop optimiste ni trop pessimiste vis-à-vis de son estimation. La crédibilité et la consistance sont évaluées au moyen de critères probabiliste basés sur des moyennes d'écart types d'estimations tel que le NCI¹, l'ANEES² et la NEES³ [DLH98, LZ01, BS90, BS92, BSL93]. Elles peuvent aussi être étudiées à travers les enveloppes d'incertitude à 2σ ou 3σ ou à l'aide des ellipses d'incertitude qui décrivent les mêmes écart types

1. NCI : Non Credibility Index

2. ANEES : Average Normalized Estimation Error Squared

3. NEES : Normalized Estimation Error Square

- à 2σ et 3σ [ZIBPJ08, LBDS04].
- La précision en matière de localisation peut être évaluée selon des critères d'erreur moyenne ou instantanée. Les erreurs moyennes telles que l'erreur quadratique moyenne RMSE⁴, l'erreur euclidienne moyenne AEE⁵ et l'erreur géométrique moyenne GAE⁶, traduisent les performances globales de l'estimateur en donnant un indice de précision qui prend en compte à chaque instant l'ensemble des instants passés. Ce genre de critère est utile pour départager des approches sur le critère de la précision dans un scénario de test complet [DLH98, LZ01, AUBM10]. Il est parfois intéressant de mesurer la précision pendant un moment précis afin de juger les comportements des estimateurs dans ces cas. Ceci est particulièrement utile pour évaluer l'impact des aberrations ou des bruits sur les différentes approches. Afin de pouvoir départager les estimateurs en égo-localisation dans des cas comme les multi-trajets GPS ou pour des données proprioceptives aberrantes, nous avons besoin de critères de précision instantanés. Les critères de précision instantanée que l'on peut utiliser sont : l'erreur euclidienne EE⁷ et les erreurs axiales de positionnement. Dans notre approche nous supposons ne disposer d'aucune source d'information extérieure à part le GPS. La comparaison à la vérité terrain se fait donc par rapport à un autre GPS plus précis, qui est le RTK : un GPS d'une précision centimétrique.
 - La robustesse se caractérise aux cas limites de l'application, d'où l'intérêt des critères instantanés. La robustesse est étudiée suivant des critères complémentaires à l'analyse de l'utilisateur du comportement des estimateurs dans les cas limites. La notion de robustesse dépend toujours du moment étudié, de l'application et du résultat souhaité par l'utilisateur. Afin de classer les approches étudiées en matière de robustesse en égo-localisation, nous allons étudier leur comportement pour des cas de fonctionnement dégradé de nos capteurs. Nous allons aussi tenter de chiffrer la sensibilité dans une relation de rendement entre la crédibilité et la précision.

La précision de l'égo-localisation a toujours été le but à atteindre afin de fournir une information qui pourrait servir à une navigation autonome du véhicule. Pour cela, le critère de précision a toujours occupé la première place dans le cahier des charges des chercheurs. Néanmoins, il s'est clairement avéré que régler et calibrer un estimateur afin de satisfaire le critère de précision aux dépens des autres critères

4. RMSE : Root Mean Squared Error

5. AEE : Average Euclidean Error

6. GAE : Geometric Average Error

7. EE : Euclidean Error

de performances tels que la consistance et la robustesse est un choix inapproprié pour des applications sécuritaire et visant à devenir autonome. La précision garantit seulement un niveau d'exactitude par rapport à la réalité sur la donnée fournie par l'estimateur.

La capacité du filtre à reproduire la vraie information est très importante mais reste toutefois complémentaire à sa capacité à donner un indice de cohérence, car la vraie information n'est parfaitement connue que dans les cas simulés. Pour cela, une mesure d'incertitude est toujours associé à l'estimé. Cette mesure est celle de la consistance, elle permet de mesurer la capacité du filtre à s'auto-évaluer et donner une information sur la qualité de son estimé à travers une erreur d'estimation sous forme de variance. De l'analyse de cette dernière découle la notion de crédibilité. La crédibilité permet de juger si l'estimateur est plutôt optimiste ou pessimiste vis-à-vis de son estimé. Ces deux familles de critères ne peuvent se détacher du dernier qui est la robustesse ou son contraire la sensibilité. Un estimateur employé dans une application telle que l'égo-localisation d'un véhicule routier, doit fournir une information précise, consistante et crédible quelque soit le cas d'usage rencontré, ceci traduit sa capacité à être robuste aux aléas de la localisation routière. La robustesse traduit la capacité du filtre à fournir une localisation de bonne qualité lorsque les données capteurs sont aberrantes, absentes ou de mauvaises qualités.

6.2.1 Critères de précision

Comme énoncé auparavant, la précision va être étudiée suivant deux groupes de critères : les critères instantanés et ceux de moyenne d'erreur afin de pouvoir juger les performances des estimateurs sur le point de vue global ainsi que sur des laps de temps précis pendant les scénarios tests.

Nous commençons par les critères d'erreurs instantanées :

6.2.1.1 L'Erreur Euclidienne "EE"

Ce critère donne la distance sur le plan (O,X,Y) qui sépare la position calculée par l'estimateur et celle fournie par la référence RTK. La distance entre les deux points de positionnement est calculée suivant l'expression de la *distance Euclidienne* :

$$EE = \sqrt{\tilde{X}^T \tilde{X}} \quad (6.1)$$

avec $\tilde{X} = \hat{X}_{k|k} - X_{ref}$.

6.2.1.2 Les erreurs axiales

Ce critère donne l'erreur séparément pour chaque axe à chaque instant. Le calcul se fait suivant la formulation de la *distance de Manhattan (taxi-distance)* linéaire la plus courte entre deux points suivant l'axe X ou Y.

$$\left\{ \begin{array}{l} E_x \\ E_y \end{array} \right\} = \hat{X}_{k|k} - X_{ref} = \begin{bmatrix} \hat{x}_{k|k} \\ \hat{y}_{k|k} \end{bmatrix} - \begin{bmatrix} x_{ref} \\ y_{ref} \end{bmatrix}$$

Ces erreurs axiales ainsi que leurs moyennes permettent de décomposer les performances des estimateurs en localisation sur l'axe longitudinal ou latéral. La considération des erreurs axiales et de l'erreur euclidienne permet d'analyser le comportement instantané du filtre et de voir les conséquences des différentes situations sur la localisation à chaque instant.

Parallèlement aux critères instantanés, nous étudions aussi la performance globale d'un estimateur sur l'ensemble du test. Un ensemble de critères de précision moyenne est présenté dans ce qui suit, chaque critère se distingue par la signification de son expression et l'interprétation donnée à sa mesure.

6.2.1.3 L'erreur quadratique moyenne "RMSE"

L'erreur quadratique moyenne représente la mesure de précision la plus commune dans le domaine de la recherche scientifique. Cette grandeur est l'approximation naturelle de l'écart-type moyen des différences entre les valeurs prédites et les valeurs observées (erreur d'estimation). La RMSE est définie par l'expression suivante :

$$RMSE(\hat{X}_k) = \sqrt{\left(\frac{1}{k} \sum_{i=1}^k \|\tilde{X}_i\|^2 \right)} = \sqrt{\left(\frac{1}{k} \sum_{i=1}^k \tilde{X}_i^T \tilde{X}_i \right)} \quad (6.2)$$

La RMSE représente en analyse probabiliste, la meilleure approximation de l'erreur standard $\sqrt{E[\tilde{X}^T \tilde{X}]}$ sur un échantillon fini. Cette erreur standard est le critère d'optimalité le plus utilisé pour les estimateurs en terme d'erreur et est la plus mathématiquement élaboré. La RMSE est une mesure de précision assez connue. Cependant, elle n'a pas une interprétation physique simple et est dépendante de l'échelle de mesure. La RMSE a tendance à être accompagné d'autres critères telle que l'erreur euclidienne moyenne "AEE" [RLZ06].

6.2.1.4 L'erreur euclidienne moyenne "AEE"

L'erreur euclidienne moyenne peut être aussi appelée *Erreur Moyenne Absolue* MAE⁸. Extraite de la notion de distance euclidienne, l'erreur euclidienne moyenne représente la moyenne des erreurs réelles instantanées $E \left[\|\tilde{X}\|^2 \right] = E \left[\sqrt{\tilde{X}^t \tilde{X}} \right]$ tandis que l'erreur quadratique moyenne est une approximation de l'erreur standard $\sqrt{E(\tilde{X}^t \tilde{X})}$. L'erreur euclidienne moyenne "AEE" est définie par :

$$AEE(\hat{X}_k) = \frac{1}{k} \sum_{i=1}^k \|\tilde{X}_i\| = \frac{1}{k} \sum_{i=1}^k \sqrt{\tilde{X}_i^T \tilde{X}_i} \quad (6.3)$$

L'AEE exprime mathématiquement la distance moyenne séparant l'estimé de la référence, et physiquement dans notre application la moyenne des distance euclidiennes. La figure 6.1 page 98 montre les erreurs de mesures suivantes dans l'ordre de leur notation $\{-0.4650, 0.3710, 0.7283, 2.1122, -1.3573, -1.0226, 1.0378, -0.3898, -1.3813, 0.3155\}$. Le résultat final est une AEE de 0.9181 *m* et une RMSE de 1.0710 *m*. Ici l'AEE exprime l'erreur euclidienne moyenne en amplitude mais il est difficile de donner un sens physique à la RMSE parallèlement à sa pertinence probabiliste. Car si elle est difficilement interprétable physiquement, la RMSE permet l'analyse et la caractérisation de la dispersion des erreurs. Si on suppose que l'erreur suit une distribution gaussienne, L'AEE peut être converti en RMSE mais l'inverse n'est pas possible sans connaissance précise de la distribution des erreurs. Pour ces raisons, plusieurs travaux de recherche sur l'évaluation de la précision des estimateurs tel que [RLZ06] et [LZ01], préconisent l'AEE par rapport à la RMSE.

L'erreur quadratique moyenne RMSE et l'AEE sont des critères d'analyse d'erreurs moyennes basées sur le concept de la moyenne arithmétique. Plus leurs valeurs sont faibles plus l'estimateur est considéré comme précis. Le critère qui suit se base quand à lui sur la moyenne géométrique.

6.2.1.5 L'erreur géométrique moyenne "GAE"

Il est bien connu que les erreurs calculé sur la base de moyennes arithmétiques sont largement influencé par les erreurs instantanées de grandes valeurs. Cette influence reste moins importante chez l'AEE qu'avec la RMSE. Une solution à cette sensibilité, est d'utiliser une moyenne d'erreur à base de moyenne géométrique. L'erreur géométrique moyenne "GAE" est définie par l'expression suivante :

8. MAE : Mean Absolute Error

$$GAE(\hat{X}_k) = \left[\prod_{i=1}^k \sqrt{\widetilde{X}_i^T \widetilde{X}_i} \right]^{1/k} \quad (6.4)$$

Pour optimiser l'implémentation numérique de cette expression, elle est souvent simplifiée de la manière suivante :

$$GAE(\hat{X}_k) = \left[\prod_{i=1}^k \sqrt{\widetilde{X}_i^T \widetilde{X}_i} \right]^{1/k} \equiv \text{Antilog} \left[\frac{1}{k} \sum_{i=1}^k \ln \sqrt{\widetilde{X}_i^T \widetilde{X}_i} \right]$$

Sachant que $\text{Antilog}(x) = 10^x$ nous pouvons donc écrire :

$$GAE(\hat{X}_k) = 10^{LGAE(\hat{X}_k)} \quad (6.5)$$

avec

$$LGAE(\hat{X}_k) = \frac{1}{2k} \sum_{i=1}^k \log_{10} \sqrt{\widetilde{X}_i^T \widetilde{X}_i}$$

Sachant que $a^x = \exp(x \ln(a))$, nous pouvons exprimer la GAE par l'expression suivante aussi :

$$\begin{aligned} GAE(\hat{X}_k) &= \exp \left[\frac{1}{k} \sum_{i=1}^k \ln \sqrt{\widetilde{X}_i^T \widetilde{X}_i} \right] \\ GAE(\hat{X}_k) &= \exp \left[\frac{1}{k} \sum_{i=1}^k \ln \left(\widetilde{X}_i^T \widetilde{X}_i \right)^{1/2} \right] \\ GAE(\hat{X}_k) &= \exp \left[\frac{1}{2k} \sum_{i=1}^k \ln \left(\widetilde{X}_i^T \widetilde{X}_i \right) \right] \end{aligned} \quad (6.6)$$

Cette dernière expression est la plus optimisée du point de vue calcul numérique. Il faut tout de même noter que pour une analyse de résultats avec la GAE, il est obligatoire de remplacer les valeurs nulles (si ce cas particulier se présente) par une valeur égales à 1. Ceci n'influence pas la GAE car la multiplication par 1 ou la somme avec $\ln(1) = \log_{10}(1) = 0$ ne change rien.

Comme expliqué précédemment, La RMSE est une bonne mesure d'erreurs quadratiques mais elle est difficilement interprétable physiquement. L'AEE vient compenser cette limite puisque elle représente physiquement la moyenne des erreurs




FIGURE 6.1 – Comparaison des critères de précision

réelles instantanées par rapport à la référence. Cependant, ces deux mesures ont un point négatif commun qui est la sensibilité aux grandes valeurs d'erreurs. La GAE vient combler ce dernier point en employant une autre approche de moyenne. Effectivement la GAE se base sur la moyenne géométrique contrairement aux deux premiers critères qui se basent sur le principe mathématique de la moyenne arithmétique. Cette particularité de la GAE lui permet d'être moins sensible aux pics d'erreurs instantanés et non persistants. L'AEE étant moins sensibles aux grands pics d'erreurs, sa valeur est théoriquement inférieure à la RMSE et reste supérieure à celle de la GAE sauf pour le cas où l'on dispose d'un seul échantillon $N = 1$ qui donne une égalité $AEE = GAE$. La GAE étant moins sensible que l'AEE nous obtenons alors le classement théorique suivant $GAE \leq AEE \leq RMSE$. Ainsi l'impact des grandes erreurs temporaires est plus important pour la RMSE et est à un minimum pour la GAE. L'intérêt principal d'utiliser la GAE est d'être moins influencé par les pics de valeurs aberrantes en restant proche de la valeur de la moyenne des erreurs réelles instantanées. Par conséquent, l'écart entre la GAE, AEE et RMSE peut être utilisé pour détecter la présence de valeurs aberrantes élevées temporaires. Plus ces trois critères de moyennes sont proches, plus les erreurs sont homogènes (pas de pic d'erreurs significatifs) et vice-versa. Lorsque $GAE = AEE = RMSE$, ceci peut être considéré comme preuve qu'il n'y a pas de fluctuations dans l'erreur et qu'elle peut donc être considérée comme un biais qu'il sera possible de compenser par la suite. La figure 6.1, reprenant le même jeu d'échantillons d'erreurs précédent, montre le comportement de ces critères face à de grandes erreurs ponctuelles. Les valeurs finales obtenues sont les suivantes : $RMSE = 1.0710$, $AEE = 0.9181$ et $GAE = 0.7608$.

Ces trois critères représentés par la figure 6.1 et développés dans ce qui a précédé, représenteront par la suite les principaux critères qui permettront de classer les filtres en terme de précision. Aussi, les allures des courbes de ces critères permettront en complément d'autres critères de juger la robustesse des filtres.

6.2.2 Consistance et crédibilité d'un estimateur

6.2.2.1 Consistance

Un estimateur est considéré comme consistant si les erreurs des estimations fournies par cet estimateur satisfassent les deux conditions décrites par les deux équations suivantes 6.7 et 6.8 [BSL93, LBDS04]. La consistance traduit la confiance que l'opérateur peut associer à une information (mesure, estimation, prédiction, etc).

$$E [X - \hat{X}] \equiv E [\tilde{X}] = 0 \quad (6.7)$$

$$E \left[(X - \hat{X})(X - \hat{X})^T \right] \equiv E \left[\tilde{X} \tilde{X}^T \right] \leq P \quad (6.8)$$

Plus explicitement, ces deux conditions de consistance veulent dire : pour un nombre d'échantillons (mesures) fini, l'erreur d'estimation doit présenter les propriétés statistiques suivantes :

1. L'erreur d'estimation de l'état est non-biaisée (centrée en 0).
2. L'erreur quadratique moyenne réelle (exacte) correspond aux covariances calculées.

Dans le travail de caractérisation des critères de validations des estimateurs en matière de consistance, Ndjeng finit par retenir deux conditions découlant de celles citées auparavant [NN09]. Ces deux conditions deviennent alors les deux critères suivants :

1. L'erreur entre l'estimé et le vrai état du système doit être centrée en zéro et avoir une matrice de variance-covariance plus petite que celle de l'estimé.
2. L'innovation (différence entre la prédiction et l'observation) doit également être non biaisée et satisfaire la même condition de variance-covariance.

La définition appliquée à une estimée \hat{X} ayant une matrice de covariance P se traduit donc par les équations 6.7 et 6.8 appliquées sur les erreurs réelles et les innovations séparément, ce type de notions est le plus souvent employé dans des cas de fusion de données ensembliste [GB05].

Pour un cas pratique comme le notre, la vérité terrain n'est jamais parfaitement connue car elle est aussi entachée d'erreurs, puisqu'elle est mesurée par un autre instrument de mesure. Dans notre cas la référence est un GPS RTK centimétrique dans le cas idéal mais qui peut aussi souffrir des perturbations et occultations de l'environnement qui entoure le véhicule pendant qu'il évolue dedans. Donc, l'erreur réelle ne peut être connue pour un cas pratique et la première condition ne peut être vérifiée qu'avec un test statistique en simulation.

Le niveau de consistance d'un algorithme d'estimation peut être aussi étudié en examinant l'erreur quadratique d'estimation normalisée NESS⁹ et la NIS¹⁰. Ces deux mesures statistiques permettent de savoir si l'estimé est biaisée, si l'erreur estimée est faible par rapport aux erreurs réelles et si la covariance de l'erreur est trop faible. Ces notions sont toujours transposées par rapport à une base théorique statistique définie par un intervalle déterminé en posant que la moyenne des innovations suit une loi statistique χ^2 avec un nombre de degrés de liberté connu. Pour plus de détails voir "Construction d'un intervalle de confiance par la loi χ^2 " dans [NN09]. La figure

9. NEES : Normalized Estimation Error Squared

10. NIS : Normalized Innovation Squared

6.2 montre un exemple d'intervalle de confiance suivant la loi χ^2 ayant 5 degrés de liberté. Pour cette exemple, en appliquant la statistique d'erreur NIS ou NESS nous pouvons alors dire selon les conditions que :

1. Si la statistique de l'erreur se trouve au delà de borne supérieure de l'intervalle r_2 alors :
 - (a) Soit l'estimé est biaisée.
 - (b) Soit l'erreur estimé par le filtre est trop faible par rapport aux erreurs réelles (filtre trop optimiste).
 - (c) Soit la covariance fournie par le filtre est trop faible (filtre trop optimiste).
2. Si la statistique de l'erreur se trouve en dessous de r_1 la borne inférieur de l'intervalle, alors l'erreur ou la covariance fournie par le filtre peuvent être considérées comme trop élevées par rapport aux valeurs réelles (filtre trop pessimiste).
3. Si la statistique de l'erreur est entre les deux bornes, Le filtre est considéré comme bien réglé et l'erreur estimée peut être dite consistante par rapport aux erreurs réelles.

6.2.2.2 Crédibilité

La crédibilité d'un estimateur peut être étudiée à l'aide de notions qui découlent de la NEES telles que sa moyenne l'ANEES¹¹ et l'indice de non-crédibilité NCI¹². L'ANEES représente un indicateur de crédibilité mais ne permet pas d'avoir une comparaison entre les approches du fait que les propriétés de l'ANEES proviennent de celles de la NEES (voir les trois cas de bornes d'intervalle de confiance présentés à la fin de la section précédente). Le NCI est un indicateur plus précis que la crédibilité d'un estimateur et il a l'avantage d'être invariant par rapport à la dimension de l'estimateur ce qui pourrait permettre une comparaison entre approches. Le problème pour un test expérimental est que son principe de calcul repose sur la différence entre deux matrices P et \sum . P est la matrice de variance covariance de l'erreur d'estimation et \sum est la matrice de variance covariance de la MSE (l'erreur quadratique moyenne exacte). \sum est impossible à estimer avec exactitude pour un test de conduite réel.

Il reste tout de même une mesure accessible pendant nos tests que l'on pourra exploiter pour tester la consistance et crédibilité de nos estimateurs. Sachant que le filtre de Kalman étendu est prouvé non biaisé, consistant, crédible et intègre pour

11. ANEES : Average NEES

12. NCI : Non-Credibility Index




FIGURE 6.2 – Intervalle de consistance construit par une densité de probabilité suivant une distribution χ^2 avec 5 degrés de liberté

notre application [NN09, MGLG05, Mou06, Lan06]. Nous allons nous orienter vers des indicateurs de contenu en information tel que les enveloppes 2σ ou 3σ et les ellipses d'incertitude. Ces indicateurs permettront de savoir si les filtres sont trop optimistes ou trop pessimistes, en référence aux valeurs affichées par le filtre de Kalman étendu.

6.2.2.3 Le contenu en informations

La matrice \hat{P}_k qui est la matrice de variance covariance de l'erreur d'estimation du filtre, contient l'information d'incertitude que le filtre associe à son estimé \hat{X}_k .

$$\hat{P}_k = \begin{bmatrix} \sigma_x^2 & \sigma_x\sigma_y & \sigma_x\sigma_\theta \\ \sigma_x\sigma_y & \sigma_y^2 & \sigma_y\sigma_\theta \\ \sigma_x\sigma_\theta & \sigma_y\sigma_\theta & \sigma_\theta^2 \end{bmatrix} \text{ sachant que } (x, y, \theta) \text{ sont les composantes du vecteur}$$

d'état \hat{X}_k . Si les valeurs dans cette matrice son grandes, cela veut dire que le filtre est incertain sur son estimé. Si les valeurs sont au contraire faibles, cela veut dire que l'estimateur est quasi-certain de son estimé. Il est tout à fait possible de faire croire la matrice \hat{P}_k en y intégrant un bruit de stabilisation. Néanmoins cette pratique est à éviter et n'est pas nécessaire pour un filtre et des bruits de mesures et de processus préalablement bien configurés. Prendre \hat{P}_k trop grande fait perdre de l'information au filtre et donnera un filtre trop imprécis après plusieurs cycles consécutifs [Mou06].

On peut comparer les matrices \hat{P}_k respectives de chaque filtre pour les même tests afin d'en comparer la consistance. Pour comparer deux matrices, on procède généralement à la comparaison de leur trace ou déterminant. Le déterminant de \hat{P}_k n'a pas vraiment d'interprétation physique et la trace peut en avoir une si elle est considérée pour des sous-matrices de \hat{P}_k (sous matrice de position et sous matrice d'orientation). Il est d'autant plus utile de décorrélérer la comparaison en prenant chaque écart type à part. Nous pouvons alors construire des intervalles d'écart types autour de l'erreur estimée. Ces intervalles permettront de comparer la consistance des filtres entre eux et de savoir s'ils sont plutôt pessimistes ou optimiste. Il est alors possible d'évaluer l'incertitude de mesure des filtres sur chaque axe (x et y) séparément sous l'hypothèse que l'erreur d'estimation suit une loi gaussienne. L'enveloppe à 2σ permet théoriquement de délimiter 95% d'erreur et à 3σ , 99,7% d'erreur est délimitée.

Prenant le même concept des enveloppes d'écart types à $n\sigma$ avec $n \in \mathbb{N}^*$, les ellipses d'incertitude permettent également d'illustrer l'incertitude du filtre sur son estimé. La figure 6.3 montre l'ellipse d'incertitude associée à l'estimé de l'égo-localisation de véhicule. Les valeurs déterminants les grandeurs des axes et l'orientation de l'ellipse sont calculés à l'aide des valeurs propres et vecteurs propres de la matrice \hat{P}_k suivant la démarche décrite dans [SC86]. Les longueurs des axes de




FIGURE 6.3 – Ellipse d'incertitude d'estimation de l'égo-localisation

l'ellipse sont obtenues en pondérant les racines carrées des valeurs propres de la sous-matrice $\hat{P}_k = \begin{bmatrix} \sigma_x^2 & \sigma_x \sigma_y \\ \sigma_x \sigma_y & \sigma_y^2 \end{bmatrix}$ de façon à ce que l'ellipse soit à 3σ . L'orientation de l'ellipse est quand à elle obtenue à partir des vecteur propres de cette sous-matrice et l'ellipse est centrée ensuite à la position estimée du véhicule.

De la même manière pour la matrice \hat{P}_k , la matrice R_k de l'incertitude de mesure GPS peut être elle aussi illustrée sous forme d'ellipse. La figure 5.6 page 5.6 montrant une illustration d'un test sous matlab d'égo-localisation avec l'approche SPF en montre un exemple. Dans cette figure nous pouvons donc constater que le filtre SPF est plus précis que le GPS car il est plus proche de la référence et qu'il est plus confiant. Cependant, nous pouvons sur cette image reprocher au SPF son optimisme car l'ellipse dans le cas consistant devrait englober la position de la référence. Quand l'ellipse englobe la référence, ceci veut dire que même si le filtre n'estime pas la position du véhicule exactement à la position de la référence, la position réelle du véhicule reste tout de même dans les valeurs probables. Si la référence ne se trouve pas dans l'ellipse, alors elle ne fait pas partie des possibilités de positionnement de

l'égo-véhicule ce qui est inconsistant, sauf si la référence est mesurée par un outil ou via une observation. Dans ce cas là (référence mesurée) il faut attribuer une incertitude aussi à la référence et en faire une ellipse. La condition devient donc que l'ellipse d'incertitude de l'estimation du filtre soit plus petite que celle du GPS et croise celle de la référence. En complément aux critères présentés, Il existe encore une dernière propriété souvent employée dans la localisation et qui est l'intégrité.

6.2.2.4 Intégrité

L'intégrité vise à vérifier que le système fonctionne comme prévu, ce qui signifie qu'il n'y a aucune déviation entre le comportement du système attendu et la réponse courante. Une telle déviation dans le comportement d'un estimateur peut provenir d'une erreur des paramètres de correction, ou de la violation d'une des hypothèses sur laquelle la modélisation du système ou du bruit est fondée, comme un multi-trajet (réflexion, retard) ou une importante croissance de l'erreur de mesure du récepteur [LMBBG⁺08].

La définition de l'intégrité dans le SARP¹³ est : "une mesure de la confiance qui peut être placée dans l'exactitude des renseignements fournis par l'ensemble du système". L'intégrité comprend la capacité d'un système à fournir en temps opportun les avertissements valables pour l'utilisateur (alertes). Par ailleurs, l'intégrité est souvent spécifiée par son inverse (risque d'intégrité). Le risque d'intégrité peut être défini comme la probabilité de fournir un signal qui est hors de la tolérance sans avertir l'utilisateur dans une période donnée du temps [RCVT01]. L'intégrité d'un système de localisation est une mesure de la confiance qui peut être accordée à l'exactitude des informations délivrées par ce système. Dans [QON06], les auteurs proposent de surveiller 3 indicateurs pour vérifier l'intégrité d'un Map Matching : *I*) résidus de distance, *II*) résidus de cap « heading residuals », *III*) un indicateur lié à l'incertitude du Map Matching [BLF⁺09].

6.2.2.5 Conclusion

On voit d'après ces différentes définitions de critères de consistance et d'intégrité, que la consistance se distingue en une qualité à fournir des résultats qui ne sortent pas d'un certain domaine d'acceptabilité, alors que l'intégrité est plutôt la capacité à fournir des réponses répondant aux contraintes du système sans pour autant avoir un domaine de confiance. Ce qui nous conduit à voir l'utilisation de l'intégrité comme indicateur de confiance ou non confiance « cas de non intégrité » pour produire des

13. SARP : GNSS Standards And Recommended Practices, published in November 2001

alertes visant à avertir l'utilisateur. La consistance sera cependant utilisée comme une condition de convergence ou élément appuyant la stabilité d'un système. Les tests de consistance probabiliste faisable en simulation étant faits et validés dans des travaux précédents pour l'EKF en égo-localisation multi-capteurs [Mou06, NN09] ainsi que pour le PF [Lan06]; Nous procéderons seulement à l'analyse expérimentale des ellipses d'incertitude et des enveloppes 3σ pour comparer la consistance et l'optimisme des approches étudiées en comparaison par rapport à l'EKF et au PF.

6.2.3 La robustesse

Les estimateurs d'état sont fondés théoriquement sur certaines hypothèses et approximations (ex. normalité probabiliste) à des fins d'optimalité. Ces approximations de lois de probabilité ainsi que les approximations en modélisation des processus et celles des bruits, génèrent un écart entre la vraie loi de probabilité et celle obtenue. Cette divergence de la vérité n'est pas vraiment quantifiable pour un cas expérimental et reste plus ou moins importante suivant la pertinences des hypothèses qui conditionne l'estimateur et la précision des approximations employées pour la modélisation du système étudié et des différents phénomènes environnementaux (bruits, parasites). Additionnellement, les conditions de fonctionnement de l'estimateur peuvent être dégradées par la présence d'observations (mesures) aberrantes. Les valeurs aberrantes peuvent provenir d'une défaillance d'un capteur ou de l'influence d'un phénomène environnemental sur ce capteur. Dans de nombreux cas de conduite routière en milieu urbain, l'accumulation des écarts entre lois de probabilité en plus de l'importance des valeurs aberrantes, font s'éloigner de l'optimalité. Dans les cas limites, les notions de conservation des hypothèses et de continuité des lois de probabilité utilisées sont à remettre en question. Afin de juger ces effets sur les estimateurs, il est donc nécessaire d'étudier leur robustesse.

6.2.3.1 La robustesse en égo-localisation

La définition de la robustesse d'un estimateur diffère d'une application à une autre. Une définition assez généraliste de la robustesse en estimation d'état est : la robustesse d'un estimateur d'état consiste en sa capacité à atténuer l'effet des observations aberrantes ponctuelles, en conservant les propriétés au voisinage du modèle théorique employé [BL92].

La robustesse d'un filtre est étudiée dans le cas de l'égo-localisation routière à travers l'évaluation des impacts des aberrations sur le fonctionnement de l'estimateur selon deux aspects :

1. Impact des valeurs aberrantes ponctuelles sur la précision de l'estimation :
 Pour des tests expérimentaux, la principale difficulté est de différencier les valeurs aberrantes des valeurs significatives provenant des capteurs. Les capteurs fournissent généralement un indice de confiance aux données de mesures Y_k via une matrice de variance covariance R_k . Le problème se situe dans les cas limites où le capteur a tendance à associer une matrice de confiance traduisant une bonne confiance à une mesure aberrante. Ceci est le cas pour le GPS dans les cas des multi-trajets (multi-réflexion du signal GPS), la figure 3.1 page 26 en illustre l'exemple. Le GPS fixe la valeur de R_k selon son mode de fonctionnement (différentiel, normal, dégradé) et selon le nombre de satellites visibles. Pour un multi-trajet où le GPS est en mode normal avec plus de 4 satellites visibles, la matrice R_k ne sera pas du tout cohérente par rapport à l'aberration de la mesure détériorée par la distance supplémentaire apportée par la réflexion. Il convient donc de ne pas éliminer les valeurs considérées comme aberrantes mais de les prendre en compte afin d'en étudier l'impact sur le comportement des différentes approches.

2. Impact des forts changements de dynamique sur la précision de l'estimation :
 Les changements dynamiques brusques tels qu'un freinage d'urgence, une accélération, un virage serré, ou des manœuvres de parking sont aussi problématiques que les problèmes de mesures. Effectivement, lors d'un changement brusque de dynamique, la difficulté est de catégoriser la mesure Y_k qui arrive comme étant bonne et non comme aberrante. Si nous reprenons le cas précédent des multi-trajets GPS avec une mesure de vraisemblance R_k correcte, il est impossible de catégoriser cette mesure en tant que changement de dynamique ou aberration sans l'aide des autres capteurs et de la dynamique du véhicule actuelle. Dans ce type de situation, il est intéressant de faire une analyse de comportement des différents filtres et d'en déduire un classement des performances en robustesse.

De manière complémentaire à l'analyse de comportement dans les cas de scénarios limites, il est utile d'avoir une notion quantitative de la robustesse ou de son inverse (la sensibilité) afin de pouvoir départager les performances des différentes approches de manière précise quand celles ci se rapprochent. Nous proposons donc dans ces travaux une analyse de sensibilité et de robustesse basée sur la complémentarité des erreurs et de leurs vraisemblances associées. Cette analyse quantitative est forcément jointe à l'analyse de comportement afin de pouvoir trancher pour les cas ambiguës. Le calcul se fait en différence de pourcentage de performance en précision d'abord, ensuite les approches sont classées dans l'ordre suivant leur moyenne de précision. En prenant la meilleure performance comme référence à 100%, nous pouvons donc

exprimer la différence de précision en pourcentage $A_i\%$. Ce classement de précision est ensuite complété par un classement d'incertitude (robustesse ou sensibilité dans les cas de perturbations). De la même manière que pour le critère de précision, nous prenons cette fois les écarts types associés aux erreurs de chaque approche. Les moyennes de ces écarts types sont ensuite classées dans l'ordre. Ensuite, en procédant de la même manière, nous obtenons un classement en différence de pourcentage en écart type entre les différentes approches. Puisque ces pourcentage d'écarts types, décrivent la différence de confiance que chaque approche a en son estimation, nous pourrions dire qu'une approche est plus ou moins sensible de $S_i\%$ par rapport à l'approche la plus robuste. L'indice S_i ¹⁴ de sensibilité et A_i ¹⁵ de précision seront calculés simplement comme une différence de deux pourcentages de performances comme le décrivent respectivement les équations 6.9 et 6.10. Il faut bien noter que les performances des approches sont relatives par rapport à celle du GPS afin d'avoir une norme pour avoir ensuite une équité de la répartition des notes S et A .

$$S_i = ((\overline{\sigma}_i / \overline{\sigma}_{GPS}) - (\overline{\sigma}_{ref} / \overline{\sigma}_{GPS})) .100 \quad (6.9)$$

$$A_i = ((MSE_i / MSE_{GPS}) - (MSE_{ref} / MSE_{GPS})) .100 \quad (6.10)$$

Avec $\overline{\sigma}_{ref}$ et MSE_{ref} les meilleures performances en matière d'incertitude et d'erreur respectivement. Ces notes sont les $\overline{\sigma}_i$ et MSE_i de l'approches considéré comme référence (l'approche référence en précision peut différer de celle en incertitude mais elle est généralement la même). La meilleure performance en erreur est naturellement celle ayant la plus petite valeur. La meilleure performance en incertitude est celle ayant la valeur la plus grande si on traite la sensibilité et la valeur la plus petite si c'est plutôt la robustesse. Ce principe s'explique du fait que, lorsqu'une approche ayant une bonne précision affiche un faible écart type, cela veut dire qu'elle est confiante et du cout robuste aux aberrations s'il y en a eu. Lorsqu'une approche affiche une grande valeur d'écart type cela veut dire que malgré sa bonne performance en précision elle reste incertaine de son estimation et est donc sensible aux bruits et aux perturbations. Il faut tout de même se méfier des cas (trop optimiste) où l'écart type est de faible valeur et l'estimation est erronée. Dans ce cas l'estimateur n'est pas considéré comme robuste mais plutôt trop optimiste. D'où l'intérêt d'associer toujours l'étude en précision et celle du comportement lors des aberrations avec celle des incertitudes avant d'exprimer un avis en utilisant les indices 6.9 et 6.10 de sensibilité et de précision.

14. S : Sensitivity

15. A : Accuracy

Chapitre 7

Tests et analyses des performances

Sommaire

7.1	Introduction	109
7.2	Implémentation	111
7.3	Les scénarios	114
7.4	Analyse et comparaison des performances	115
7.5	Conclusion	139

7.1 Introduction

Nous analyserons dans cette partie les données enregistrées lors des tests expérimentaux. Afin d'accomplir une comparaison objective, des données réelles sont collectées lors de scénarios de conduite sur une zone urbaine des pistes de Satory-Versailles. Le recueil des données se fait en utilisant un véhicule du laboratoire de l'IFSTTAR / LIVIC équipé de capteurs embarqués et de programmes d'enregistrements dédiés. Le véhicule est équipé d'un capteur de braquage du volant, un gyromètre, un odomètre et un GPS (*AG132*) à faible coût fonctionnant en mode dégradé. Ceci va permettre d'avoir des bases de données-capteurs réelles d'une conduite routière. L'utilisation d'une seule et même base de donnée est le meilleur moyen de garantir un test impartial pour toutes les approches, ces données une fois enregistrées auront les mêmes conditions de fonctionnement et auront été enregistrées sous les mêmes conditions de bruits et de perturbations environnementales. De plus, des données réelles permettent d'avoir des cas concrets qui peuvent être rencontrés lors de la conduite urbaine. Traiter ces cas devient une obligation si l'on souhaite obtenir un système

d'égo-localisation fiable pour tout utilisateur λ . Une fois les données de capteurs enregistrées, elles sont ensuite rejouées en différé dans un environnement dédié qui tourne en temps réel. Cet environnement de test est développé sous RtMaps afin de pouvoir lire les bases et exploiter les sorties au mieux pour faire un prototypage de nos applications. Les approches vont alors être appliquées sur les données enregistrées suivant un déroulement en temps réel, en aucun cas nous ne considérons avoir une donnée future ou une donnée de référence. Il n'y a pas de lissage non plus suivant l'ensemble des données passées enregistrées, puisque nos approches suivent un principe bayésien, la dernière estimation représente toujours l'accumulation de l'évolution. Les approches sont toutes implémentées dans la même logique de programmation et lancées sous les mêmes conditions matérielles (ressources informatiques) avec les mêmes paramètres de modélisations de bruits de mesures et de processus. Tout est fait pour que la comparaison des performances soit la plus impartiale possible et que chaque approche ait les mêmes conditions de fonctionnement que les autres afin de ne pas être influencée différemment. Ceci n'empêchera pas d'avoir des comportements complètement différents dans certains cas limites, suivant la base de conception de l'approche (aléatoire, bayésienne, mono ou multi-hypothèses). Pour les approches multi-hypothèses (méthodes à base de particules), le nombre de particules employées est fixé à 500 particules. Le seuil de rééchantillonnage est fixé pour garantir un minimum de 50% de particules efficaces à tout instant suivant le critère de Liu-Kong. Ayant noté des cas de divergence pour le SPF à cause d'une concentration trop rapide de l'essaim de particules (convergence prématurée); Un certain pourcentage de ses particules sont dépourvues de leur capacité de communication. Ces particules vont alors devenir des particules non évolutives et se comporteront comme des particules de filtre PF avec rééchantillonnage. Ces particules appelées (Perturbatrices) sont employées afin d'empêcher une rapide concentration de l'essaim pour éviter la divergence du filtre. Les perturbatrices vont représenter 90% des particules du SPF et les 10% restantes seront des particules évolutives suivant un principe de PSO. Afin d'éviter que les 10% ne se concentrent en un point et que les 90% représentent un filtre à particules classique, une gestion aléatoire de ces particules est intégrée. Les particules évolutives ou non sont choisies à chaque étape de manière aléatoire de façon à avoir des particules évolutives qui dorment et d'autre non évolutives qui deviennent à leur tour évolutives à un certain moment du processus de localisation. Cette sélection aléatoire se fait suivant une loi normale centrée en zéro avec un écart type représentant 10% de l'essaim ce qui donne une chance sur dix qu'une particule évolue pendant un cycle. Pour les approches hybrides OKPS et SPF le facteur d'inertie W est fixé à 0.2% pour garantir une contrepartie minimale de l'inertie du véhicule. Les données enregistrées par le GPS RTK différentiel et centimétrique se-

ront considérées comme références pour le calcul des erreurs, le RTK représentera la vérité terrain. Les tests seront effectués pour un même scénario de conduite effectué sous plusieurs conditions de fonctionnement. Les détails du scénario et des conditions sont explicités par la suite. Les performances des filtres seront ensuite discutées suivant les critères d'erreurs sélectionnés auparavant et illustrés par des graphiques et des tableaux résumant les performances moyennes.

7.2 Implémentation

Afin de pouvoir effectuer des tests en simulation et en re-jeu de données réelles, l'environnement de prototypage RtMaps a été choisi. Cet environnement de part sa modularité et ses diagrammes, donne la possibilité de concevoir chaque approche comme un module de localisation à part entière. Ce qui donne la possibilité d'une utilisation séparée de chaque approche ou une combinaison de plusieurs d'entre elles. Cet environnement nécessite la programmation des modules sous langage C/C++, ce qui donne une exécution rapide à nos modules. Dans le diagramme illustré par la figure 7.1, Il est clair que les modules de localisation ont besoin de modules complémentaires afin d'être testé. Dans cette optique, d'autre modules ont été modifiés ou développés tels que les modules de lecture de structure de sortie des blocks de localisation ainsi que les modules de lecture en temps réel des données capteurs. Ces modules travaillent en collaboration avec d'autre modules existants (développés auparavant dans le LIVIC ou natifs de RtMaps) tel que les modules de gestion des marquages temporelles et ceux de lecture et d'enregistrement des entrée sorties.

RtMaps permet facilement la lecture et le re-jeu de bases de données réelles enregistrées par les véhicules instrumentés et aussi la lecture de bases complètement simulées issues d'un autre environnement qui est le moteur de simulation SiVIC. Il permet aussi d'enregistrer les résultats et rapports de fonctionnement dans plusieurs formats possibles compatibles avec Matlab et avec des éditeurs de textes génériques. Les résultats enregistrés pour nos tests seront analysés suivant les critères détaillés auparavant et implémentés sous Matlab.

L'intérêt principal de travailler sous cet environnement est de standardiser les travaux effectués au LIVIC en matière d'aide à la conduite, ce qui permettra par la suite de tester puis combiner les meilleures approches afin de faire le prototypage d'un système autonome complet de véhicules routiers.

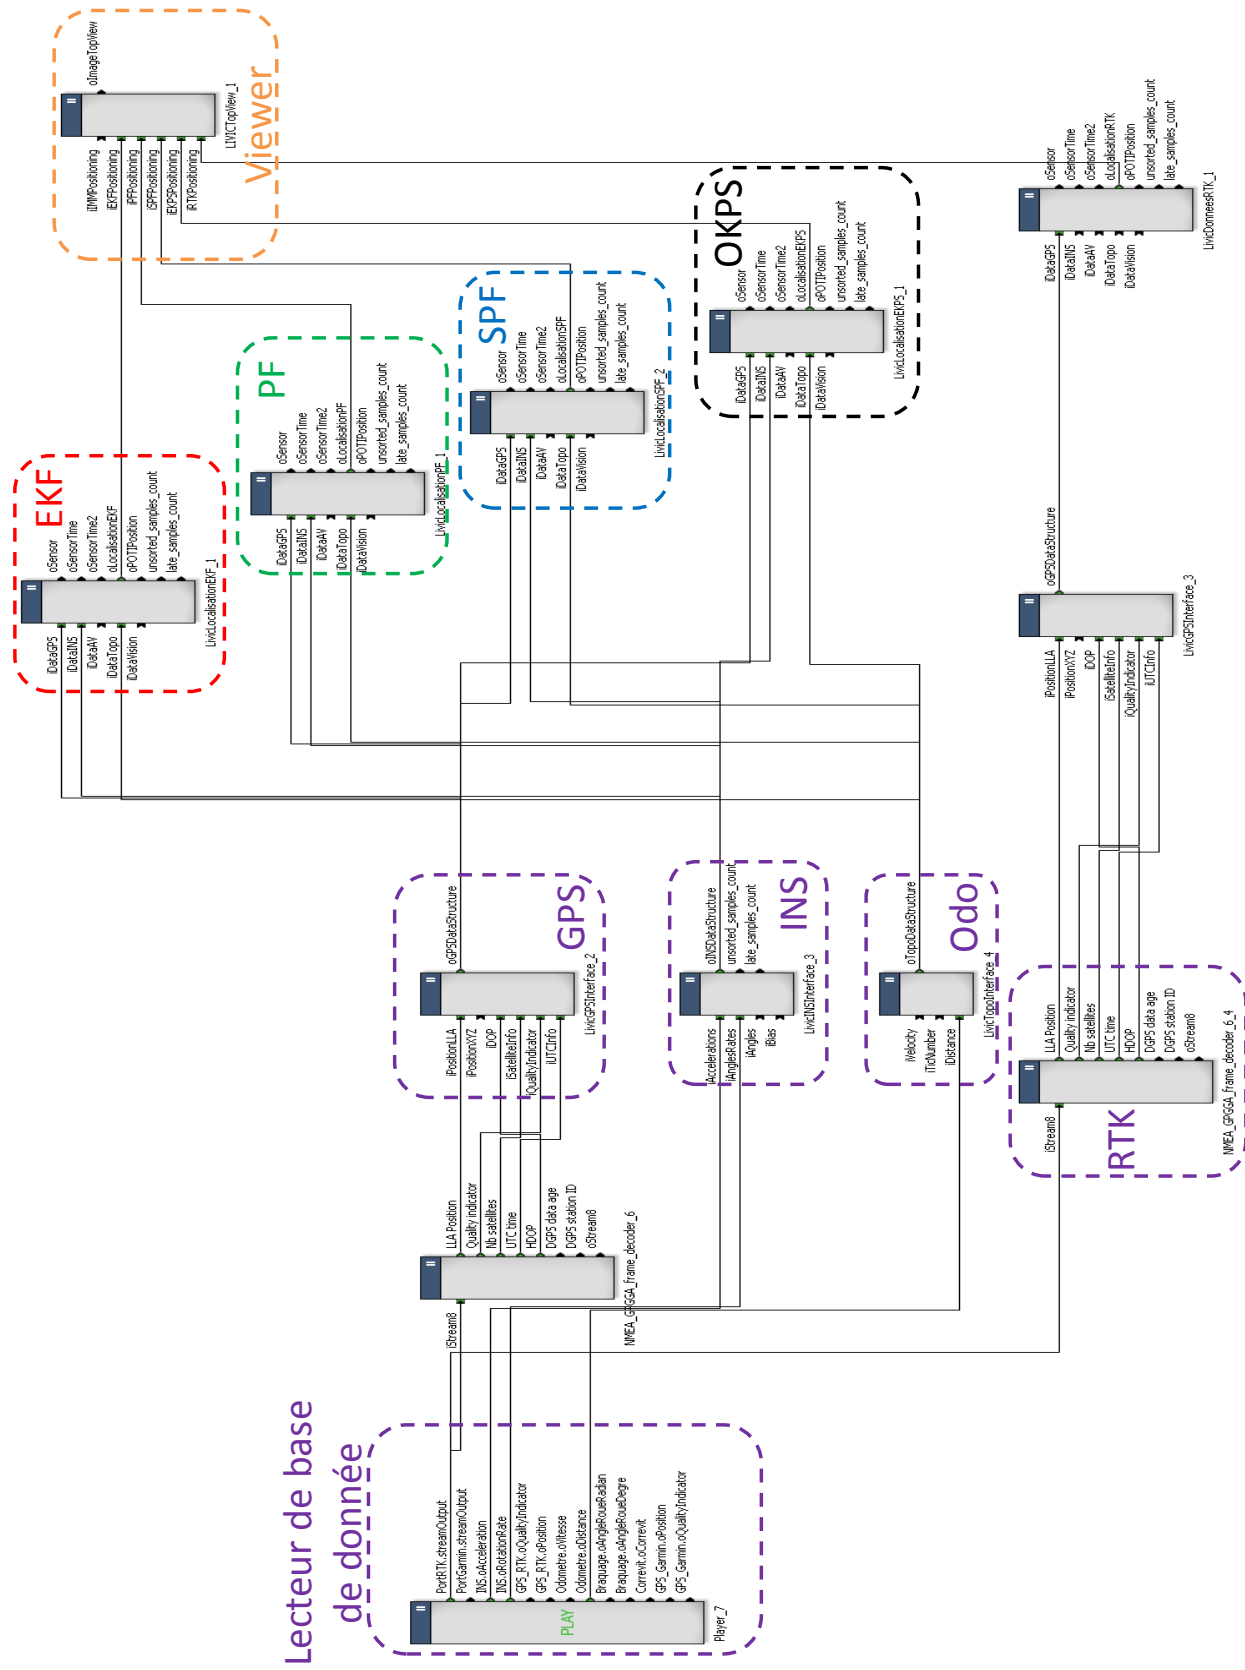


FIGURE 7.1 – Diagramme de test des approches d'égo-localisation sous RtMaps

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"



FIGURE 7.2 – Pistes Satory : Routière et Val d’Or

Localisation multi-hypothèses pour l’aide à la conduite : conception d’un filtre "réactif-coopératif"

7.3 Les scénarios

Les tests de conduites sont faits sur les pistes de Satory-Versailles. Comme le montre la figure 7.2, ces pistes sont un circuit de test formé de deux parties, une première partie (Piste Routière) urbaine contenant des ligne droites et des virages et une autre partie (Piste Val d'Or) passant par la forêt. Les tests vont considérer exclusivement les données récoltées sur la partie routière pour deux raisons principales. La première est d'avoir un comportement de conduite urbaine avec ces avantages ainsi que ces inconvénients. La deuxième raison est que le RTK souffre de perturbations dans la partie forêt et ne nous permet pas d'avoir une référence cohérente afin de calculer les erreurs et étudier de façon objective les performances. Le scénario de conduite étudié sera donc un départ en conduite normale sans accélération forte jusqu'à atteindre une vitesse de conduite urbaine aux alentours des 50 *Km/h*. Le départ et l'arrivée se font aux points indiqués respectivement par les drapeaux vert et rouge dans le sens des flèches sur la figure 7.2. Ce scénario sera décliné en trois versions, une première très dégradée (GPS mode dégradé), une deuxième sans grandes dégradations (GPS mode normal) et une dernière intégrant des multi-trajets (GPS mode normal dans canyon urbain).

Le véhicule instrumenté a parmi ces modules de collecte de données un mode synchrone. Ce mode est sensé faciliter le post-traitement afin de ne pas chercher les données les plus proches temporellement pour des analyses de données ou des re-jeu. L'inconvénient de ce mode synchronisé est qu'il prend à chaque instant la dernière donnée connue de chaque capteur comme la donnée actuelle en faisant une interpolation temporelle. Sachant que les capteurs ont des fréquences assez différentes, ce mode présente des erreurs de données pour les capteurs les plus lents tels que le GPS (erreur de recalage temporel).

- Le premier test est effectué en utilisant la base de données synchrone. Comme les données sont synchronisées, les données des capteurs les plus lents sont interpolées. Ce mode fournit à chaque pas de temps une donnée pour chaque capteur en recalant temporellement les données anciennes suivant le modèle Bicyclette d'évolution du véhicule. Vu la disponibilité théorique de toutes les données à chaque pas de temps, le processus de localisation sera de réaliser à la fois la prédiction et la correction à chaque instant k . Ce genre de situation est possible lorsque les capteurs sont très rapides ou lorsque le véhicule se déplace lentement (manœuvre de parking). Le problème avec cette base de données est que la disponibilité complète des données extéroceptives et proprioceptives rend les filtres très confiants et optimistes. Les ellipses et les valeurs d'incertitude seront plus petites que la normale et le défi est d'être

capable de détecter les valeurs aberrantes en dépit de la confiance accordée à ces mesures. Cette base de données est caractérisée par un biais et un niveau de bruit élevé provoqués par la synchronisation. Les filtres doivent être robustes et précis en même temps. Comme dit précédemment, la difficulté est de filtrer les valeurs aberrantes et ne pas être pleinement optimiste quant à la qualité des données.

- Afin de tester la cohérence du filtre et de veiller à son intégrité dans plusieurs cas de figures, les deux scénarios des tests suivants sont effectués sur des données réelles de l'ensemble des capteurs, collectées de manière asynchrones. Le deuxième test sera réalisé avec les données sans aucun bruit ou dégradation supplémentaire. Les données des capteurs seront prises dans leur version brute (pas de pré-traitement du signal et pas de synchronisation). Ce test donne une idée des performances des méthodes étudiées dans le cas d'une application de localisation pour un véhicule standard équipé de capteurs à faible coût.
- Le troisième test va intégrer des perturbations simulant des multi-trajets lors des passages en canyons urbains. Ces perturbations seront intégrées aux données GPS afin de tester la réactivité et la sensibilité des filtres. Ce test final aura pour but d'évaluer les performances des approches d'égo-localisation véhicule pour un scénario de conduite urbaine.

7.4 Analyse et comparaison des performances

Dans cette partie, les filtres : EKF, PF, SPF et OKPS sont testés dans le cadre d'une application d'égo-localisation de véhicules routiers. Différents scénarios avec des bruits différents et des qualités de données différentes sont étudiés. Les tests sont effectués de manière à pouvoir classer les approches en termes de précision et de robustesse pour l'application visée. Présentés auparavant, les principaux critères de comparaison sont : l'erreur quadratique moyenne (RMSE), l'erreur euclidienne moyenne (AEE) et l'erreur géométrique moyenne (GAE) pour la catégorie des erreurs moyennes permettant d'établir une analyse des performances moyennes en précision. Les performances en temps réel instantanées seront évaluées à l'aide d'autres critères. Les critères complémentaires aux erreurs moyennes pris en compte sont : l'erreur instantanée euclidienne (EE), les erreurs axiales et les écarts-types axiaux. La robustesse du filtre sera quand à elle le résultat d'une analyse du rapport entre les erreurs moyennes, les critères instantanés et les écarts types.

Afin de garantir l'impartialité de la comparaison, les jeux de données des tests sont enregistrés dans des fichiers compatibles avec l'environnement de prototypage. Comme détaillé dans l'introduction de ce chapitre, cette manière garantit les mêmes

conditions à toutes les approches. Ainsi nous pouvons comparer la performance de chaque approche contre sa concurrente en ayant la certitude qu'il n'y a pas de paramètre qui influence une approche plus qu'une autre. Les bruits de mesures, de modélisation et de processus sont les mêmes pour toutes les méthodes et la puissance de calcul est la même aussi. Les performances des filtres décrites par les graphiques des erreurs moyennes, ceux des erreurs axiales et celui de l'erreur euclidienne permettent l'analyse du comportement des filtres à chaque étape du test pour une étude de leurs précisions. Les graphiques des écarts types fournies par les filtres permettent quand à eux une analyse de la consistance et la crédibilité des filtres de façon à pouvoir se référer à la consistance et intégrité théorique de l'EKF pour une telle application. En comparant les enveloppes à 2σ et les écarts types attribués par les différents filtres à leurs estimés, nous pouvons déterminer quelle est l'approche la plus pessimiste ou la plus optimiste afin de juger la consistance de leurs estimations. Les tableaux représenteront un résumé des graphiques des erreurs et écarts types axiaux en donnant leurs moyennes respectives. Ces moyennes de performances permettront en complément des autres graphiques de classer ensuite les approches en terme de robustesse tel qu'expliqué dans la partie traitant de la robustesse dans les critères d'évaluation.

test AG132	EKF	PF	SPF	OKPS	GPS
<i>RMSE</i>	4.37	4.37	4.35	3.89	5.87
<i>AEE</i>	4.28	4.27	4.28	3.76	5.29
<i>GAE</i>	4.18	4.16	4.22	3.60	4.38

TABLE 7.1 – Valeurs finales des erreurs moyennes obtenues pour le test AG132 Synchronisé

Les résultats du premier test effectué sur les données AG132 synchronisées sont décrits par catégories de critères de performances dans plusieurs figures. Les figures 7.3, 7.4, 7.5 et 7.6 donnent une illustration dans l'ordre de citation des critères de précision en erreur euclidienne "EE", erreur quadratique moyenne "RMSE", erreur euclidienne moyenne "AEE", et erreur géométrique moyenne "GAE". Les figures 7.7 et 7.8 représentent graphiquement les erreurs axiales et les enveloppes d'incertitudes à 2σ associées à ces erreurs axiales. Les tableaux 7.1 et 7.2 résument l'ensemble des deux groupes de graphiques précédents de manière à permettre l'analyse de la précision essentiellement avec le premier groupe de graphique (erreur moyennes). L'analyse de la consistance et robustesse se fera en complément de celle de la précision à l'aide du deuxième groupe de graphiques (erreurs instantanées et écarts types associés) en plus du tableau 7.2. L'écart entre les valeurs des erreurs moyennes RMSE, AEE, et GAE permettra de détecter la présence de fortes aberrations instantanées et de confirmer

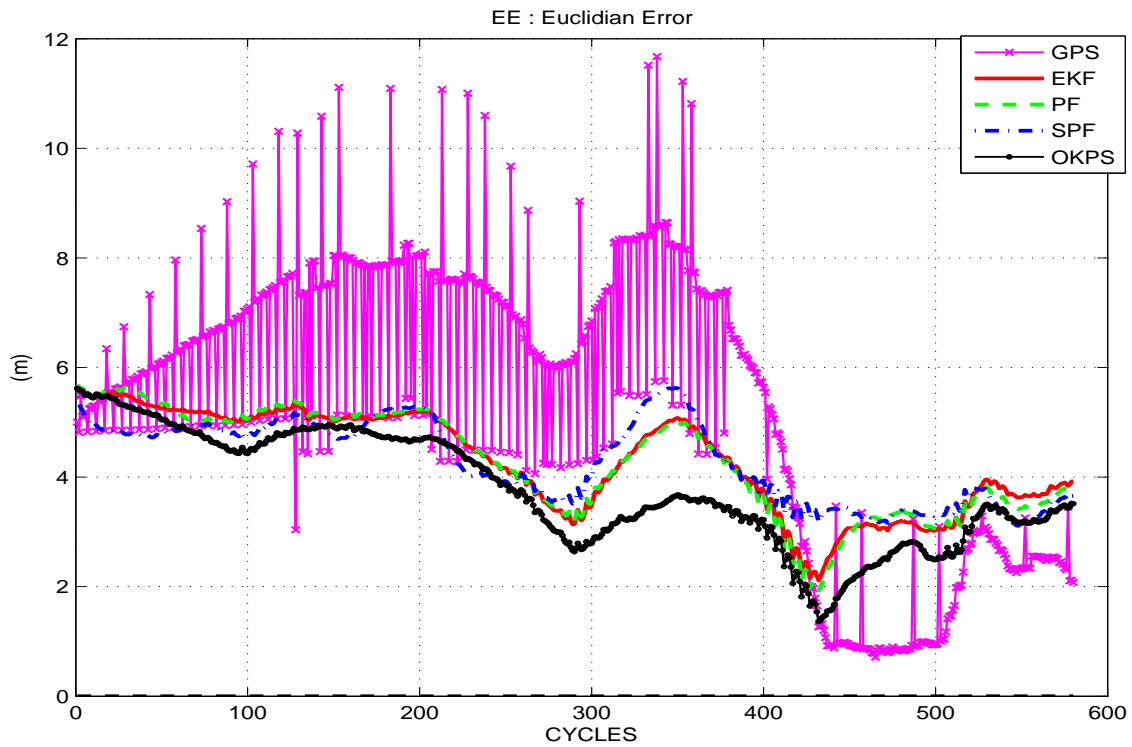


FIGURE 7.3 – Erreur Euclidienne pour des données AG132 Synchronisées

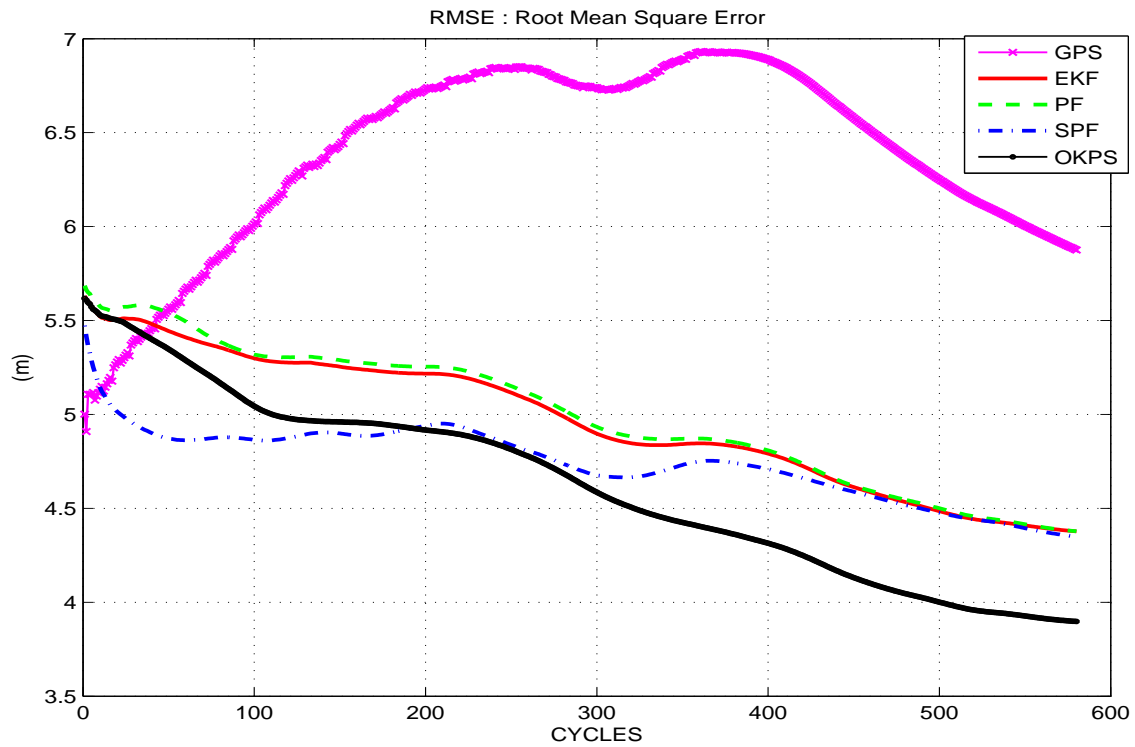


FIGURE 7.4 – Erreur quadratique moyenne pour des données AG132 Synchronisées




FIGURE 7.5 – Erreur Euclidienne moyenne pour des données AG132 Synchronisées

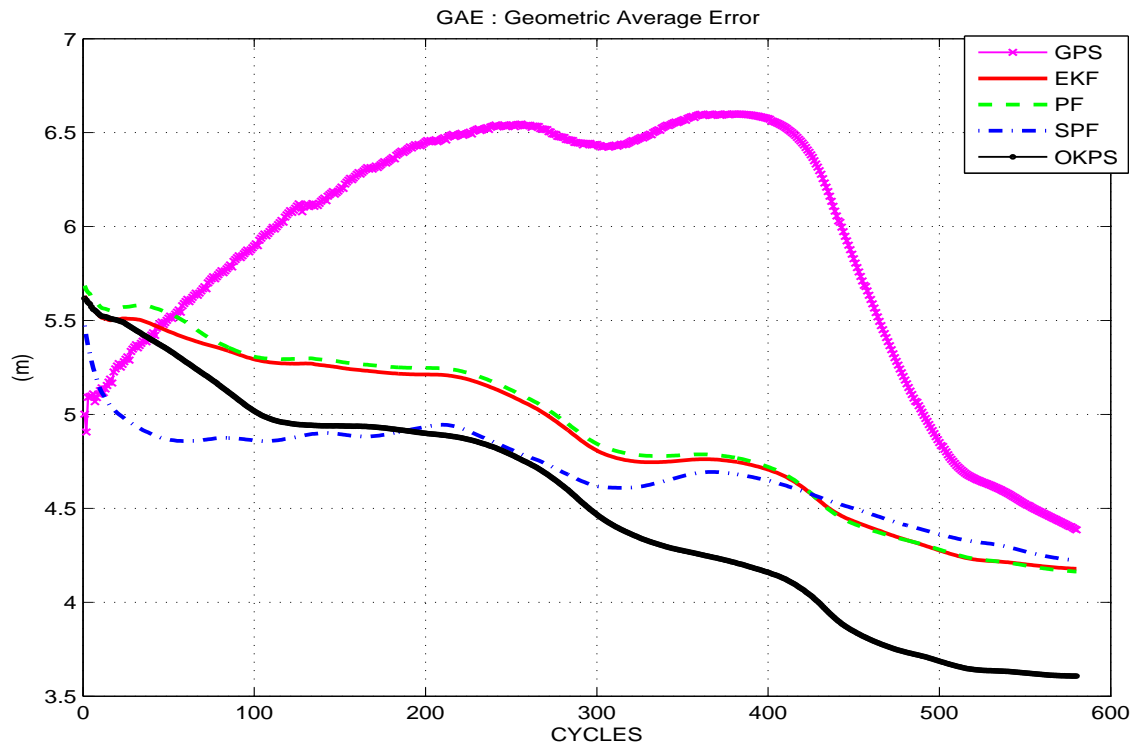


FIGURE 7.6 – Erreur géométrique moyenne pour des données AG132 Synchronisées

le caractère impulsionnel ou pas des aberrations causant les erreurs que l'on peut distinguer sur la figure de la RMSE. Cette organisation des critères et des groupes de figures sera la même pour tous les tests afin de garder une certaine rigueur dans le processus de comparaison.

test AG132	EKF	PF	SPF	OKPS	GPS
X_{mean}	-1.87	1.82	-1.91	-1.77	-2.86
σ_X	0.49	0.52	0.37	0.71	2.48
Y_{mean}	3.82	3.83	3.79	3.22	4.01
σ_Y	0.90	0.92	0.82	1.06	2.01

TABLE 7.2 – Erreurs axiales moyennes et écarts types axiaux moyens pour le test AG132 Synchronisé

Comme indiqué dans le tableau 7.1, il existe des écarts entre les valeurs de GAE, AEE et RMSE. Pour le GPS l'écart est plus important, confirmant la présence d'erreurs instantanées suivant le principe décrit par la figure 6.1 page 98 dans la partie traitant des critères et protocoles de comparaison des performances. Cependant l'écart reste modéré car les erreurs ont un caractère persistant et sont fréquentes, ce qui est visible et confirmé par l'erreur euclidienne du GPS dans la figure 7.3. Les résultats globaux en précision montrent que tous les filtres arrivent à corriger les erreurs des données traitées, le rendu en égo-localisation reste acceptable pour toutes les approches compte tenu des aberrations en entrée.

Néanmoins, les filtres restent plus ou moins attirés par les données GPS aberrantes, ceci est particulièrement visible dans les figures 7.3 et 7.7(b) entre les cycles 400 et 600. Dans cette zone le véhicule est en sortie de virage et attaque une ligne droite, les filtres sont sensibles au changement brusque de dynamique du véhicules et continuent à fonctionner dans l'espace d'état d'une dynamique de conduite en virage, les données GPS aberrantes confortant le comportement en virage, finissent par attirer les filtres en causant une déviation de la vérité terrain. Dans cette situation et dans le test en globalité l'OKPS affiche de meilleurs résultats et une meilleure robustesse aux aberrations.

L'OKPS parvient à surpasser les performances des autres filtres en faisant usage des propriétés exclusives de réactivité et coopérativité de ses particules. Pour atteindre ce résultat, l'OKPS donne une valeur de probabilité adéquate pour chaque particule à chaque pas de temps en utilisant la fonction de fitness adaptative. Ensuite, ces valeurs de probabilité de particules (scores) sont utilisées pour donner une valeur d'estimation globale à la localisation ego-véhicule. Grâce à ce mécanisme d'optimisation adaptative à l'aide d'auto-diagnostic, l'OKPS finit par fournir une localisation

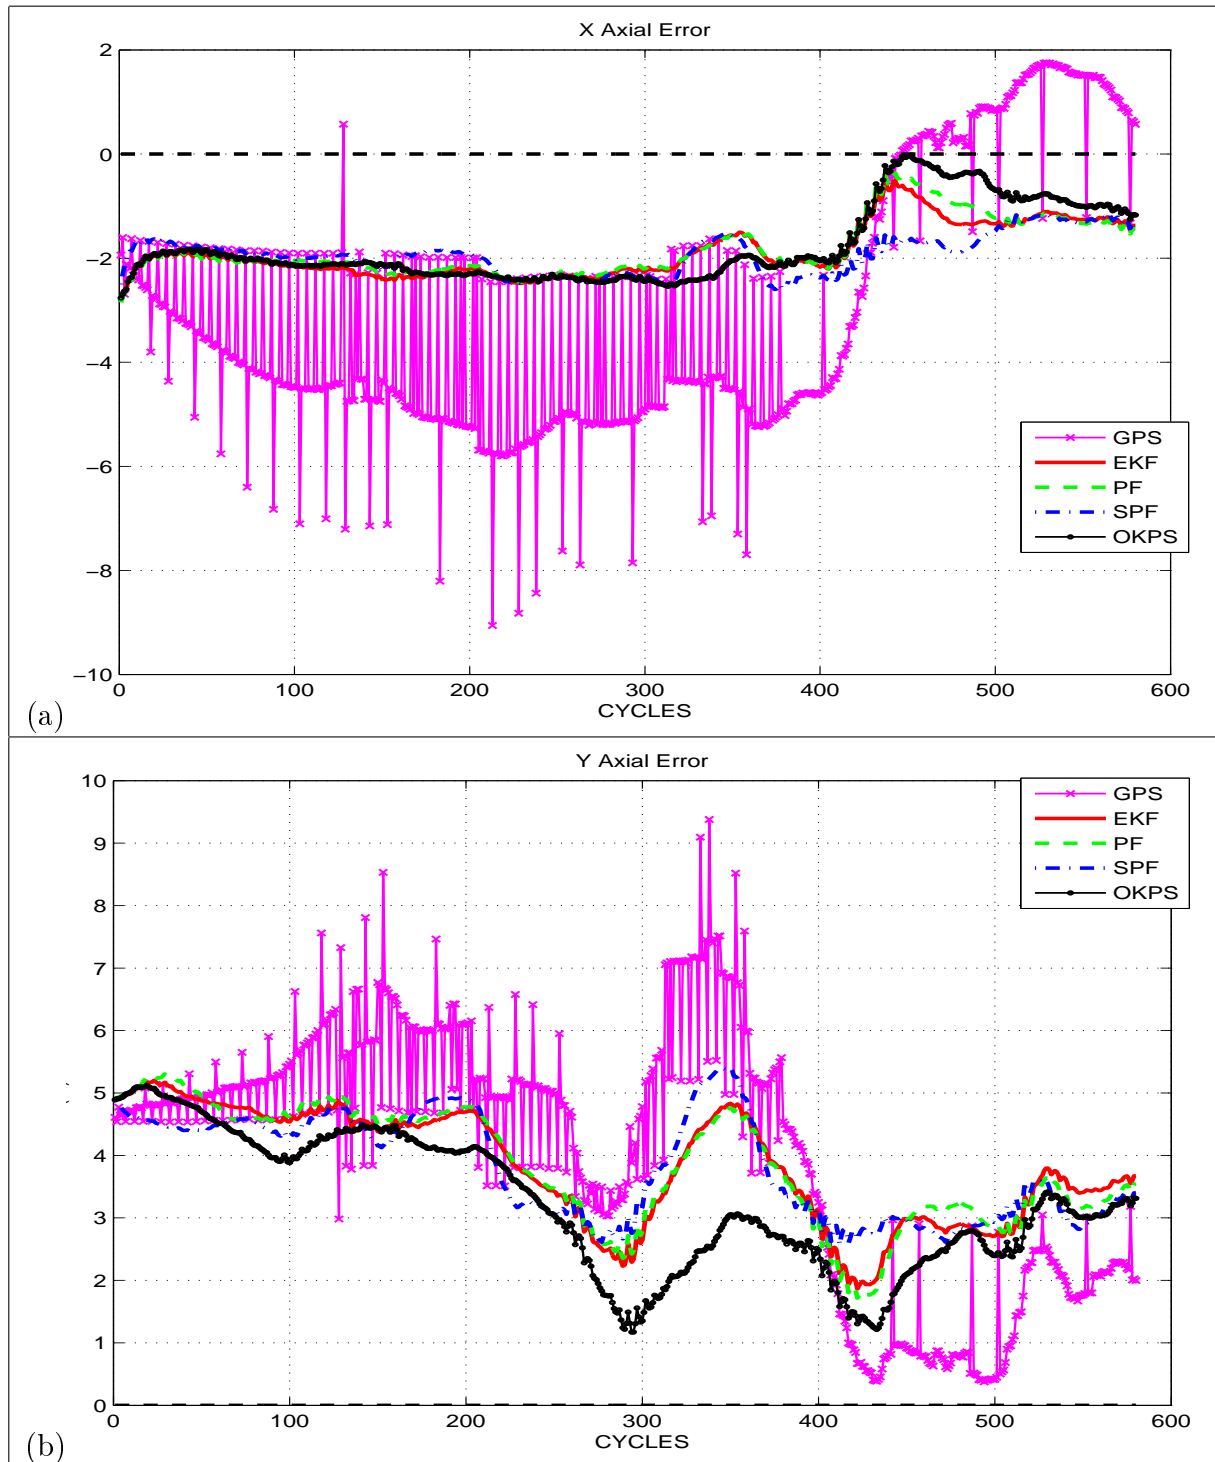


FIGURE 7.7 – Erreurs axiales pour le test AG132 Synchronisé

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

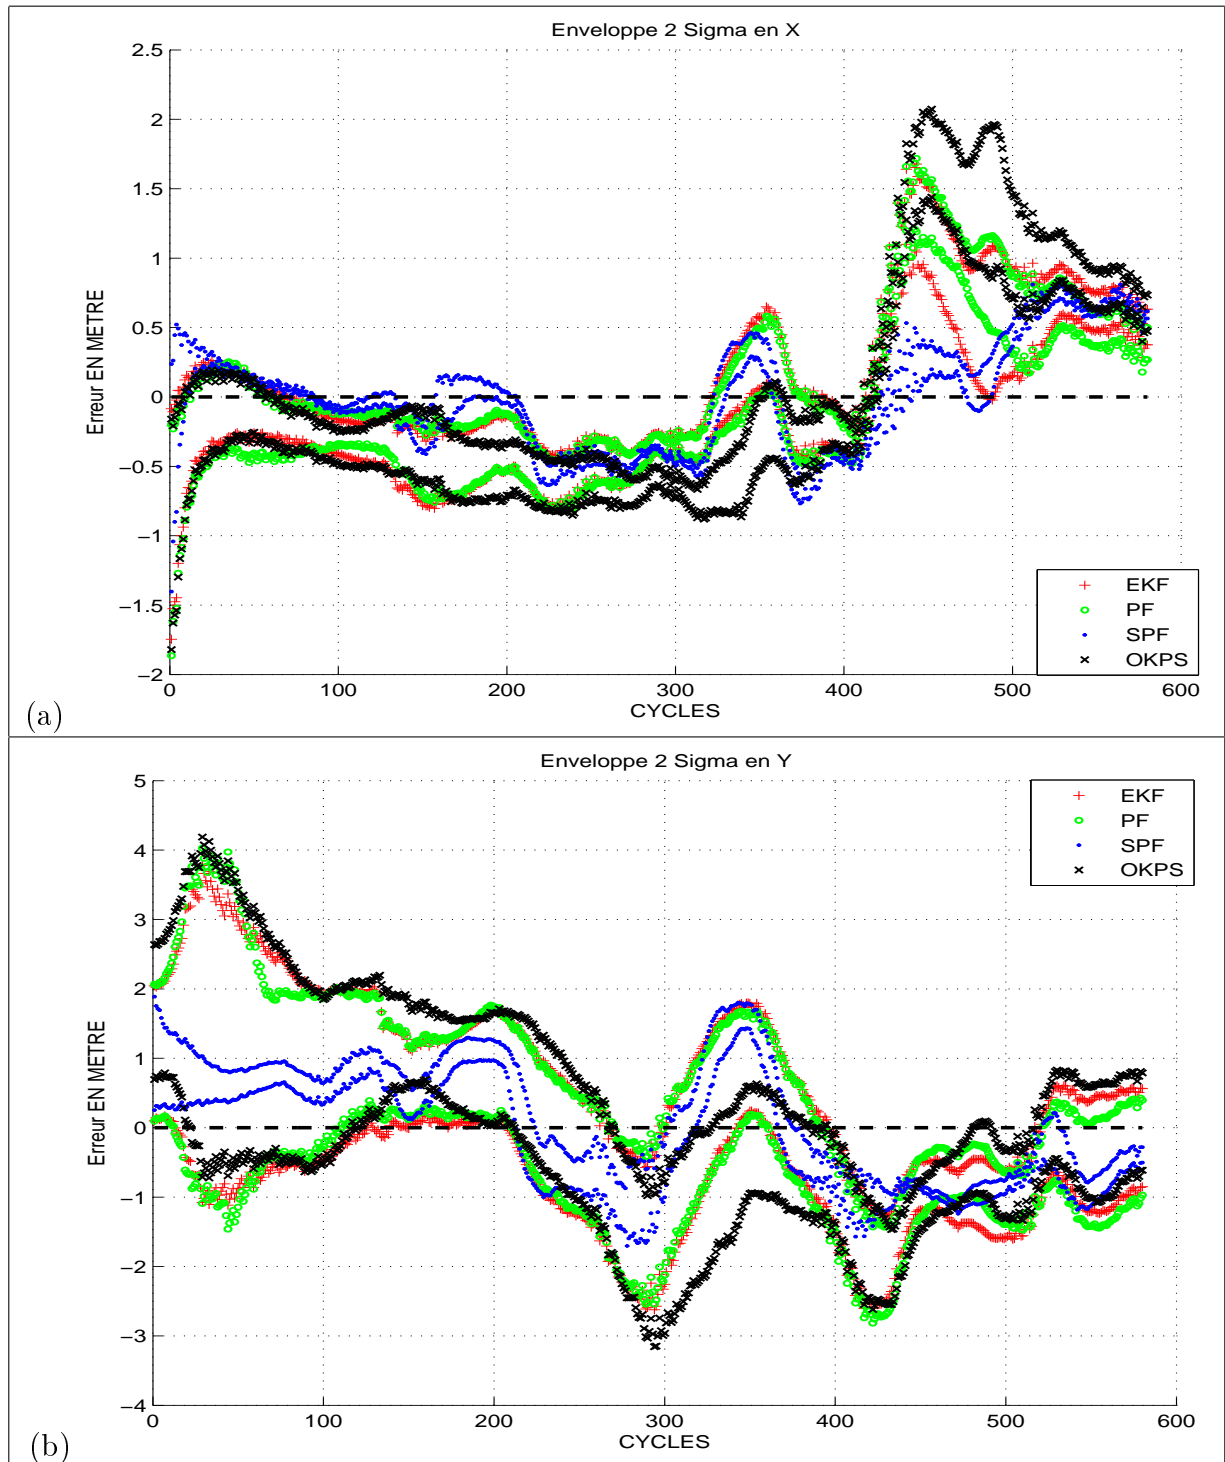


FIGURE 7.8 – Enveloppes axiales 2σ pour le test AG132 Synchronisé

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

plus précise et plus robuste aux bruits forts et aux aberrations instantanées. Les enveloppes des écarts types affichées par les figures 7.8(a) et (b) ainsi que leurs valeurs moyennes notées dans le tableau 7.2 montrent que l'OKPS reste consistant et n'est pas trop optimiste sur l'estimation qu'il fournit malgré sa précision plus élevée. Ce qui peut être noté du tableau 7.2 et de ces graphiques, c'est que le filtre SPF souffre d'un optimisme accru, ce qui l'empêche d'être consistant sur l'ensemble du test. Effectivement, l'optimisme du filtre SPF par rapport aux autres filtres est notable sur la figure 7.8 des enveloppes à 2σ et confirmé par les valeurs moyennes des écarts types dans le tableau 7.2. Que l'OKPS soit plus précis mais pas plus confiant sur son estimé que les autres filtres est un bon point en cette situation. Vu le caractère dégradé des données, cet équilibre en matière d'auto-évaluation permet au filtre de rester réactif et de ne pas diverger en ayant une confiance exagérée dans sa prédiction par exemple. Cet avantage découle directement de la capacité d'auto-diagnostic (fitness adaptative) des particules de l'OKPS et du caractère cognitif apporté par les deux notions d'évolutions permettant le mélange de liberté de mouvement (inertie) et d'attachement (influence sociale) aux autres particules.

En considérant les erreurs affichées par les différents filtres et en employant la relation entre les erreurs axiales moyennes et les écarts types axiaux moyens affichés par le tableau 7.2, l'OKPS s'avère plus précis de 11,7% que le filtre EKF et 11,4% de plus que le PF, l'OKPS est aussi 7.8% plus robuste que l'EKF et 6.8% moins sensible que le PF globalement dans ce test. Ces pourcentages sont calculés suivant le principe décrit dans l'explication des deux critères de sensibilité et de précision 6.9 et 6.10 page 108.

L'OKPS combine à la fois les informations de prédiction et de correction comme pour la plupart des filtres bayésiens, le mécanisme de pondération adaptative (fitness adaptative) et d'auto-diagnostic des particules (matrice d'incertitude) permettent au filtre d'obtenir la meilleure estimation de la position du véhicule en profitant des avantages des approches natives sur lesquelles l'OKPS établit son hybridation. Cependant, ces résultats obtenus par une pénalisation des informations capteurs (essentiellement le GPS) en raison de leur caractère dégradé peuvent ne pas être toujours à l'avantage de notre approche et éventuellement causer une divergence. Ceci est possible par exemple, lorsque les données capteurs sont de bonne précision mais que l'incertitude associé ne soit pas représentative de leur précision ; Dans ce cas le filtre aura pour réaction de pénaliser les données et de suivre un comportement majoritairement inertiel concernant l'évolution des particules. Il reste à tester si ce comportement permettant de suivre la propre voie de chaque particule reste consistant dans différents cas de figures. Afin de tester la cohérence de notre approche et de veiller à son intégrité, d'autres tests sont effectués.

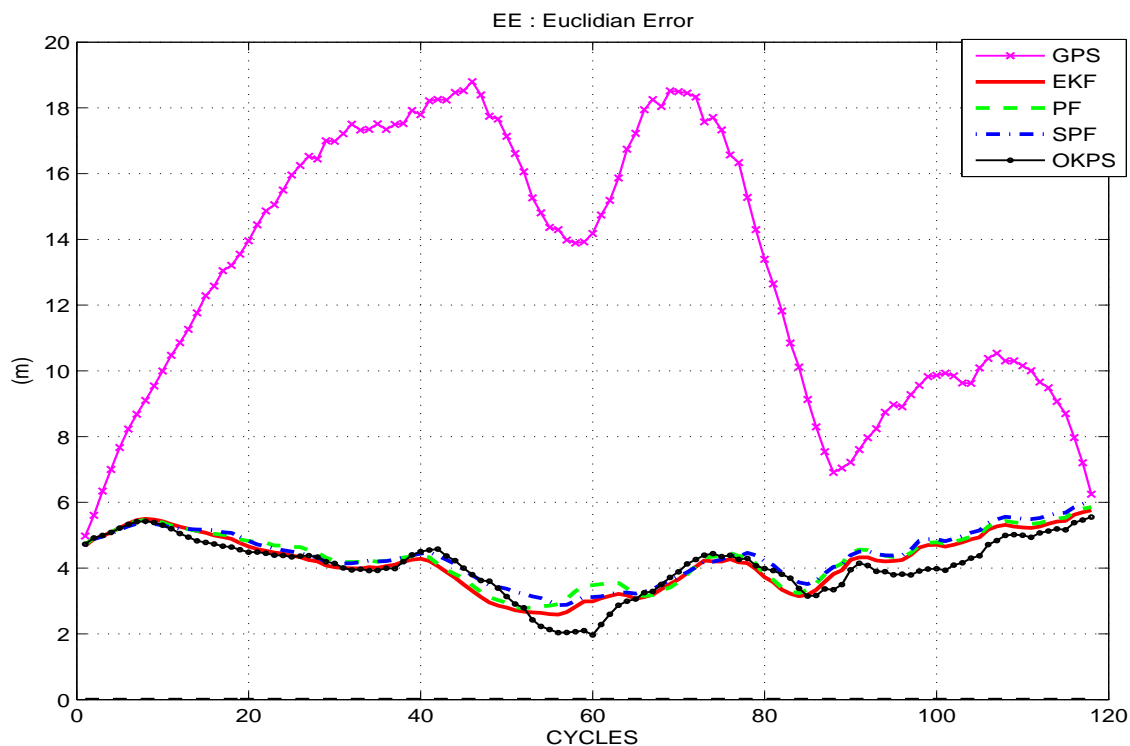


FIGURE 7.9 – Erreur Euclidienne pour des données AG132 brutes

Pour le test suivant, les données des capteurs seront prises dans leur version brute (pas de pré-traitement et pas de synchronisation). Ce test donne une idée de la performance des méthodes dans une application d'égo-localisation pour un véhicule routier standard équipé de capteurs à faible coût. Après cela, un autre test avec une perturbation GPS est effectué à l'aide d'une perturbation GPS générée et inclus aux mesures GPS. La dégradation générée simule l'effet des multi-réflexions GPS en canyons urbains. Ce test final testera les performances de localisation égo-véhicule pour un scénario de conduite urbaine et permettra de juger la réactivité et la sensibilité des filtres.

test AG132	EKF	PF	SPF	OKPS	GPS
<i>RMSE</i>	4.28	4.40	4.45	4.17	13.72
<i>AEE</i>	4.19	4.33	4.38	4.08	13.13
<i>GAE</i>	4.10	4.25	4.31	3.98	12.46

TABLE 7.3 – Valeurs finales des erreurs moyennes obtenues pour le test AG132 brute




FIGURE 7.10 – Erreur quadratique moyenne pour des données AG132 brutes

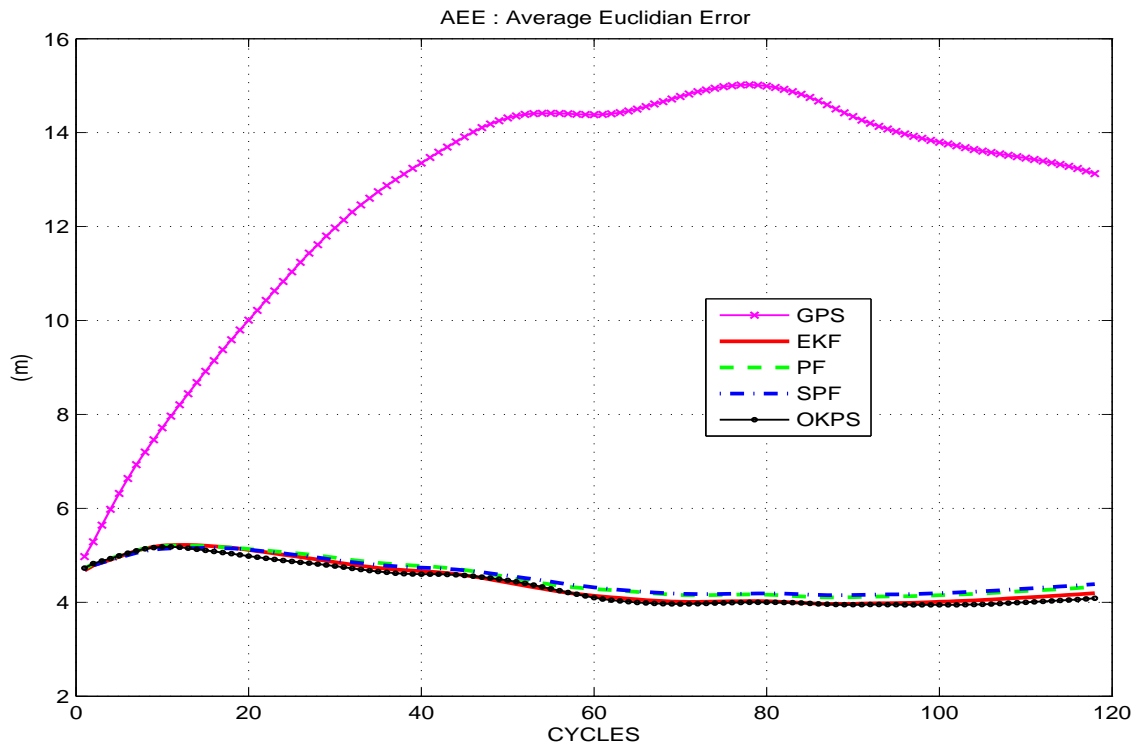


FIGURE 7.11 – Erreur Euclidienne moyenne pour des données AG132 brutes




FIGURE 7.12 – Erreur géométrique moyenne pour des données AG132 brutes

Avec ce deuxième test, les performances de notre approche vont être testées dans une situation différente que pour le premier test. Ce test utilise des données asynchrones brutes du même ensemble de capteurs employés pour le test précédent ainsi que pour le même parcours sur les pistes de Satory. Les détails du test et du scénario sont disponibles dans la partie 7.3.

Les résultats du test de données brutes asynchrones sur la piste d'essai de Satory sont présentés dans les figures 7.10, 7.11, 7.12 et 7.9 ainsi que dans le tableau 7.3 pour les indicateurs de précision moyenne. Les figures 7.13 et 7.14 résumées par le tableau 7.4 permettent en complément des critères précédents de faire une analyse du fonctionnement des estimateurs suivant le principe décrit dans la partie 6 et appliqué au test précédent.

Les critères de précision montrent que l'OKPS effectue un bon positionnement du véhicule pour des conditions normales des signaux capteurs. Les résultats affichés permettent d'assurer l'efficacité et l'intégrité de l'OKPS dans une multitude de situations et non seulement pour des situations de dégradation ou coupure du signal de mesure. Après analyse des précisions et des résultats notés par les erreurs moyennes axiales et leurs incertitudes associées, nous pouvons conclure suivant le même principe d'analyse que dans des conditions de signal acceptable, l'OKPS parvient à fournir une localisation précise et robuste. Malgré des performances assez proches, l'OKPS reste 3.6% plus précis que le SPF et 1.2% plus robuste que le PF. Pour ce test, Les filtres SPF et PF affichent quasiment les mêmes performances en adoptant des comportement proches. L'intérêt de l'hybridation PSO est visible dans la petite différence affichée par le SPF qui dépasse le filtre PF en raison de la capacité évolutive des particules du SPF. En matière de consistance, l'OKPS se montre plus optimiste que l'EKF et le PF qui ont les mêmes estimations d'incertitudes à 2σ dans les graphiques 7.14(a) et (b). Le filtre SPF reste toujours le plus optimiste parmi les autres filtres, ceci est la cause direct de la concentration de la distribution de l'essaim de particules de ce dernier.

test AG132	EKF	PF	SPF	OKPS	GPS
X_{mean}	-1.26	-1.29	-1.54	-1.30	-6.66
σ_X	1.43	1.50	1.38	1.28	8.96
Y_{mean}	3.76	3.88	3.89	3.66	4.82
σ_Y	0.69	0.66	0.63	0.78	6.41

TABLE 7.4 – Erreurs axiales moyennes et écarts types axiaux moyens pour le test AG132 brute

Ce troisième et dernier test dont le scénario est détaillé dans la partie 7.3 vise à

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"




FIGURE 7.13 – Erreurs axiales pour le test AG132 brute

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

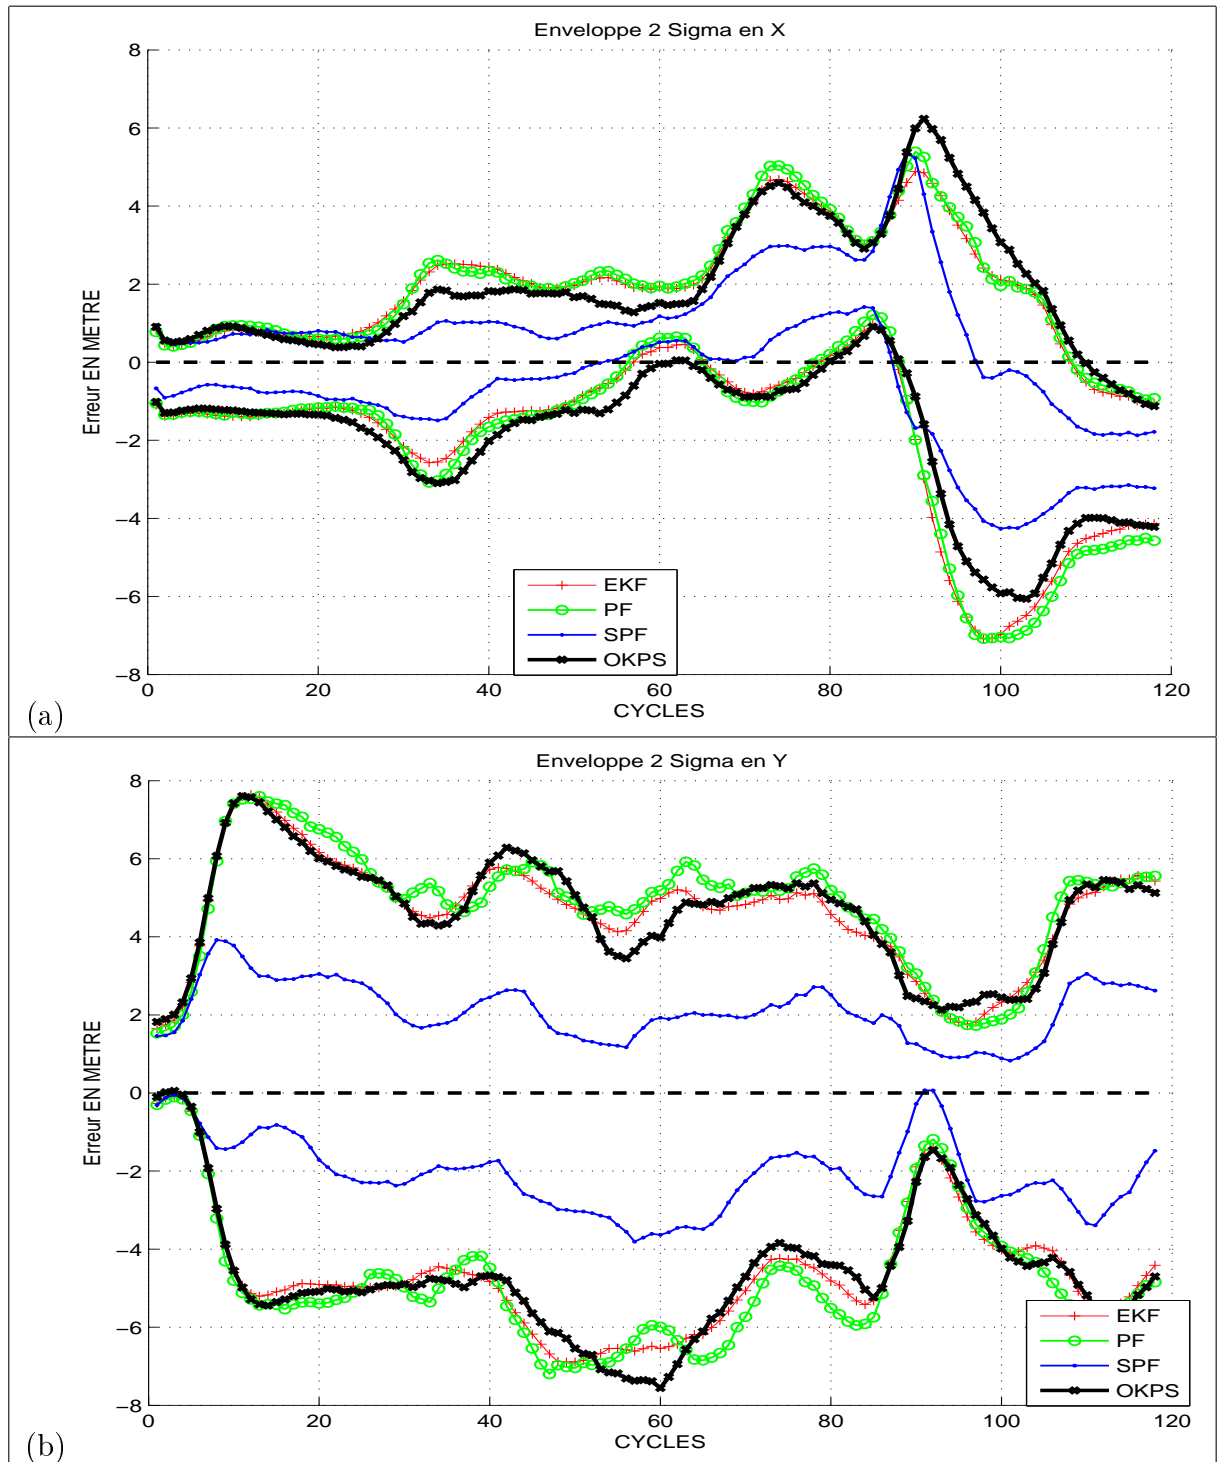


FIGURE 7.14 – Enveloppes axiales 2σ pour le test AG132 Synchronisé
 Localisation multi-hypothèses pour l'aide à la conduite : conception d'un
 filtre "réactif-coopératif"

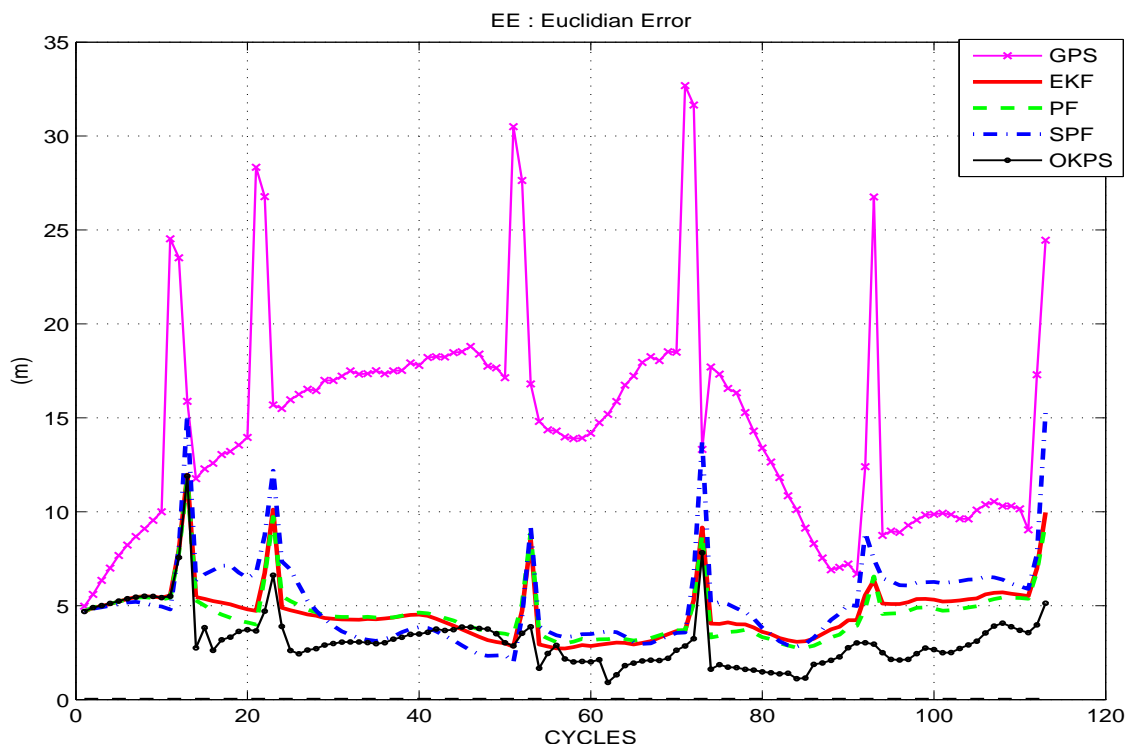


FIGURE 7.15 – Erreur Euclidienne pour des données AG132 avec des réflexions GPS

évaluer la réactivité et la sensibilité de nos estimateurs dans une application d'égo-localisation de véhicule routier dans un environnement urbain. Pour cela, des réflexions GPS telles que celles rencontrées dans les canyons urbains sont simulées et incorporées dans les données GPS réelles du test précédent. Il reste maintenant à voir l'impact de ces perturbations sur le comportement des estimateurs et à comparer leurs performances en termes de précision et de robustesse.

test AG132	EKF	PF	SPF	OKPS	GPS
<i>RMSE</i>	4.89	4.79	5.63	3.55	15.73
<i>AEE</i>	4.64	4.56	5.12	3.20	14.70
<i>GAE</i>	4.43	4.37	4.70	2.91	13.69

TABLE 7.5 – Valeurs finales des erreurs moyennes obtenues pour le test AG132 avec des réflexions GPS

Pour ce test, la répartition des critères sur l'ensemble des figures suit la même

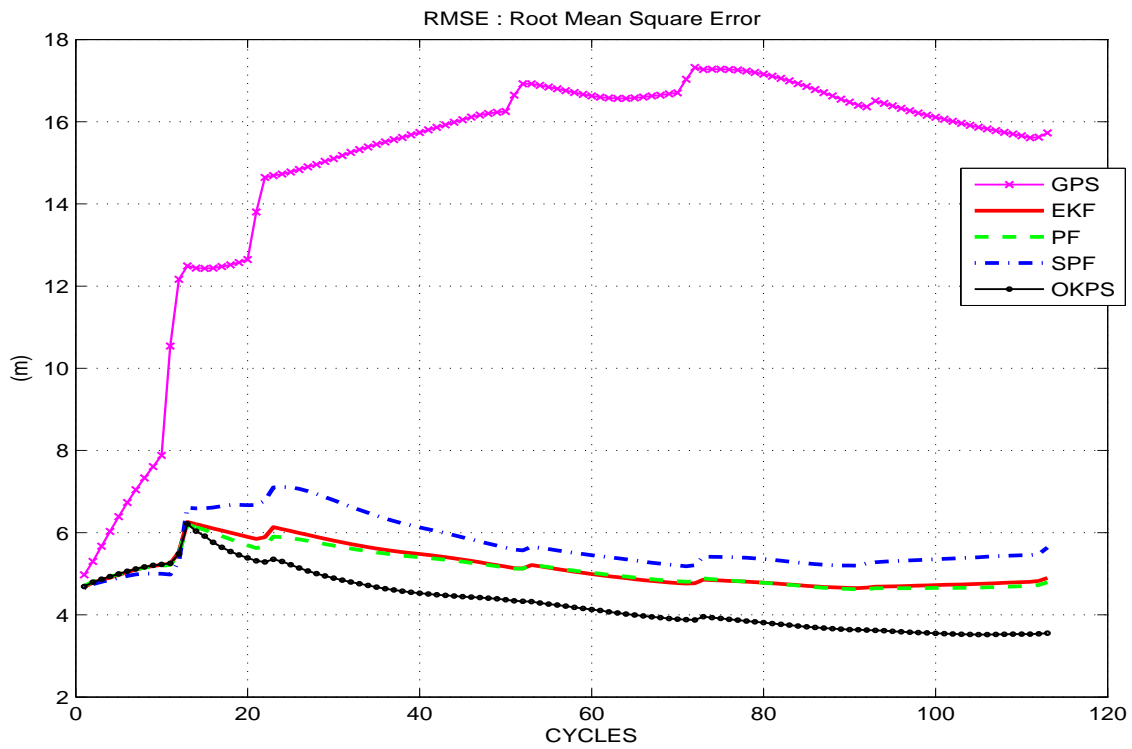


FIGURE 7.16 – Erreur quadratique moyenne pour des données AG132 avec des réflexions GPS




FIGURE 7.17 – Erreur Euclidienne moyenne pour des données AG132 avec des réflexions GPS

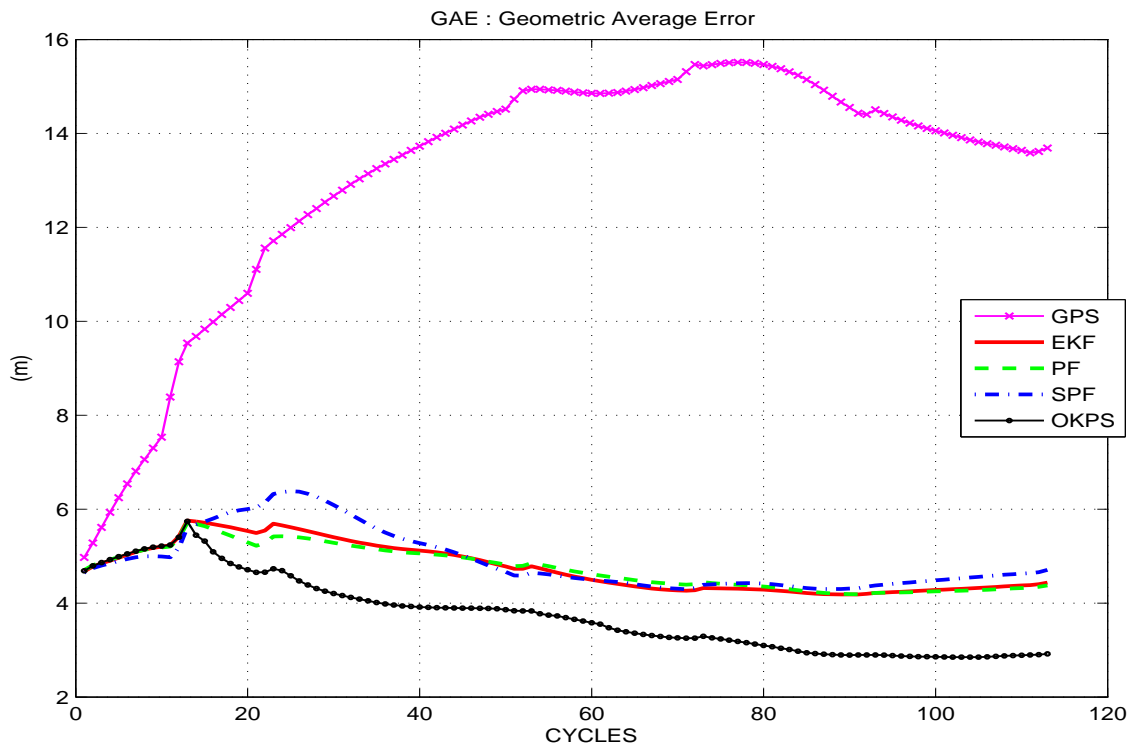


FIGURE 7.18 – Erreur géométrique moyenne pour des données AG132 avec des réflexions GPS

logique de la figure 7.15 à la figure 7.20, le tout résumé par les tableaux 7.5 et 7.6. Les erreurs affichées par les graphiques et notées dans les tableaux montrent que l'OKPS dépasse les performances des autres approches. L'OKPS se distingue en particulier dans les zones de multi-réflexion du signal GPS. Effectivement, il fournit un meilleur positionnement avec une précision plus élevée tout en restant moins sensible aux brusques perturbations du positionnement GPS (pics GPS en critères moyens et axiaux). Il est notable dans la plupart des figures et plus particulièrement la figure 7.15 et 7.20 décrivant l'erreur quadratique et les écarts types axiaux instantanément que dans les zones pics (multi-trajets) : tous les filtres sont touchés, mais le filtre OKPS reste plus précis et plus confiant sur son estimation et finit par être le moins sensible aux fortes valeurs aberrantes.

L'OKPS est conçu pour faire face à ce genre de situations, c'est pourquoi il réalise une meilleure localisation. Dans ce test, les données GPS sont ponctuellement perturbées par un bruit de multi-trajets. Ces perturbations sont indiquées par les pics de graphiques, en particulier dans les critères d'erreurs instantanées telles que les erreurs axiales et euclidiennes. L'écart entre les valeurs de RMSE, AEE et GAE de chaque approche qui est dans ce test plus important que pour les deux précédents, confirme la présence de fluctuations importantes et instantanées. Le principe de détection de fortes erreurs ponctuelles est détaillé dans l'explication accompagnant la figure 6.1 page 98.

Dans une ville avec des canyons urbains où les systèmes GNSS souffrent généralement de réflexions multi-trajets comme le montre la figure 3.1, l'OKPS sera l'approche la plus appropriée pour une application d'égo-localisation à base de fusion multi-capteurs. Les résultats affichés dans cette situation démontrent que l'OKPS est 18,4% plus précis que l'EKF et 17,9% de plus que le PF. Il est également en moyenne 7,3% plus robuste que le SPF. La réactivité apportée par l'hybridation PSO dans le SPF reste incontrôlé et provoque des réactions importantes du filtre SPF face aux pics des multi-trajets. L'intérêt de l'intégration d'une capacité d'auto-diagnostic (sur la base de matrice de variance-covariance) au filtre OKPS trouve ici tout son sens et prouve son utilité. Ce dernier test confirme aussi que le filtre OKPS conjugue bien les deux qualités de réactivité et coopérativité inspirées respectivement de l'optimisation PSO et du filtrage particulière, le tout contrôlé et calibré par une fonction de fitness adaptative basé sur les évaluations d'auto-diagnostic tirées du principe du Kalman Étendu.




FIGURE 7.19 – Erreurs axiales pour le test AG132 avec des réflexions GPS
 Localisation multi-hypothèses pour l'aide à la conduite : conception d'un
 filtre "réactif-coopératif"




FIGURE 7.20 – Enveloppes axiales 2σ pour le test AG132 avec des réflexions GPS
 Localisation multi-hypothèses pour l'aide à la conduite : conception d'un
 filtre "réactif-coopératif"

test AG132	EKF	PF	SPF	OKPS	GPS
X_{mean}	-1.44	-1.43	-0.65	-1.12	-7.67
σ_X	1.45	1.28	2.26	1.03	8.79
Y_{mean}	4.18	4.13	4.56	2.44	5.43
σ_Y	1.51	1.49	2.33	2.08	9.11

TABLE 7.6 – Erreurs axiales moyennes et écarts types axiaux moyens pour le test AG132 Synchronisé

7.5 Conclusion

L'OKPS a dépassé les performances des autres approches, notamment dans le cas des multi-réflexions du signal. Il reste également moins sensible aux valeurs aberrantes de positionnement GPS et aux changements de dynamique du véhicule que les filtres EKF, PF et SPF. L'OKPS effectue un meilleur positionnement avec une plus grande précision dans des situations différentes. Ces tests concluent que l'OKPS est globalement meilleur dans les trois scénarios et dépasse les autres filtres, en particulier en cas de conduite urbaine et lors de perturbation des données capteurs. Le caractère du filtre réactif-coopératif comme cité dans le titre de cette thèse est finalement visible dans ces tests. Le filtre SPF issu de l'hybridation PF/PSO affiche une réactivité notable et parfois au conséquences négatives, ce qui permet de faire deux conclusions : premièrement que la réactivité du filtre OKPS est bien héritée de l'hybridation PSO et deuxièmement que le filtre SPF ouvre la porte à d'autres améliorations qui peuvent toucher aussi l'OKPS et ouvrir ces deux estimateurs à d'autres applications traitant de la navigation de manière globale et pas forcément qu'en milieu routier.

Chapitre 8

Synthèse et perspectives

L'objectif final de cette thèse est décrit par son titre : Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif". Le but principal était donc de concevoir un filtre réactif-coopératif capable de gérer une localisation multi-hypothèses destinée à l'aide à la conduite. Le filtre conçu devait aussi répondre à des exigences en matière de précision, consistance et robustesse. La localisation en sortie de ce filtre se doit d'être fiable et précise afin de représenter la brique de base aux systèmes d'aide à la conduite développés par l'IFSTTAR et plus particulièrement pour le laboratoire LIVIC.

Dans la littérature et dans les travaux précédents effectués au LIVIC, nous avons pu faire une analyse de ce qui existe et de ce qui peut être amélioré. Les thèses [Lan06, Mou06, NN09] donnent une précise description de chaque technique de localisation en environnement extérieur et pour des application routière. L'analyse des ces travaux et leur étude a permis l'établissement d'un premier bilan qui synthétise l'état de l'art avant le démarrage dans une conception d'une nouvelle approche. Ce bilan se résume comme suit :

En matière de localisation routière par fusion multi sensorielle, il existe plusieurs approches à base de variantes du filtre de Kalman (EKF, DD1, DD2, UKF) ces approches ont été étudiées et comparées théoriquement et pratiquement dans les travaux suivant [ZIBPJ08, MGLG05, NNLGG09, NGL⁺09, LBDS04, GGL05]. Les variantes de Kalman ont montré des performances assez proches pour des tests de localisation routière, ce qui confirme la position de l'EKF comme la méthode la plus répandue pour ce type d'applications. Néanmoins ces approches bayésiennes ont leurs limites en matière de robustesse aux bruits et aux fortes non-linéarités à cause des linéarisations ou approximations sur lesquelles elles sont basées. Afin de combler les limites des méthodes bayésiennes, les méthodes à base de particules ont vu le jour

[SAC02, BBM09, BLF⁺09, LBCT03, Lan06]. Ces méthodes sont inspirés des méthodes utilisées pour la simulation à base de tirage aléatoire (monté carlo). Les premiers filtres particuliers montrent une bonne capacité d'estimation de distribution probabiliste mais souffrent du problème de divergence. Ce problème de divergence est corrigé par des méthode de rééchantillonnages [HSG06, BDH00, DC05, Hol04]. Les filtres particuliers avec rééchantillonnage deviennent donc précis et robuste mais demandent beaucoup de puissance de calcul. Effectivement, il s'est avéré que leur précision dépend du nombre de particules disponibles à chaque instant, ce qui dépend de la puissance de calcul à disposition. La recherche scientifique tente alors d'atténuer cette dépendance à la puissance de calcul en cherchant à optimiser au maximum le rendement probabiliste des particules d'un filtre. Cette démarche s'est traduite par l'hybridation des approches existante en matière de localisation entre elles afin de profiter des avantages de chacune. L'hybridation est aussi étudiée avec d'autres approches venues d'autres horizons telles que les approches d'optimisation opérationnelle. Ces optimisations à base d'hybridation donnent naissance au Kalman particulier et au filtre à essaim de particules [GGLV12, HNT10, JC09, TFX06, WdM01, ZPP11b].

Les travaux de cette thèse ce sont donc basées sur l'ensemble des ces méthodes et ces idées afin de proposer une approche innovante réactive-coopérative. Restant dans la tendance de recherche scientifique de ces dernières années, l'orientation adoptée est celle de l'hybridation. Reste à trouver les bons candidats à fusionner afin de concevoir l'approche visée.

L'idée de base est de comparer les point positifs et négatifs de chaque approche en matière de localisation routière puis d'essayer de faire un schéma théorique d'une nouvelle approche hybride fusionnant les briques avantageuses de chaque méthode source. L'approche naissante se nomme alors : *Le filtre de Kalman Optimisé à Essaim de Particules* "OKPS". Ce nouveau filtre a été conçu en deux étapes. La première étape a donné naissance au *filtre particulière à essaim de particules* "SPF", ce filtre est le fruit de l'hybridation entre le filtre à particules connu pour sa robustesse et sa réactivité, et la technique d'*optimisation par essaim de particule* "PSO" conçue pour des problèmes d'optimisation opérationnelle et pour simuler le comportement d'individus dans un groupe. Cette hybridation a pour but principal d'augmenter le rendement probabiliste des particules. Explicitement, ceci est censé faire gagner en précision et en temps de calcul (moins de rééchantillonnage) sans augmenter le nombre initial des particules.

Les premiers résultats de comparaison entre l'EKF, le PF et le SPF sont concluants et permettent de confirmer un gain en précision et en temps de calcul pour des tests simples. Pour des tests poussés avec des cas limites de conduite routière tel que des conditions difficiles du signal et de bruit important, le SPF se comporte de manière

exemplaire en matière de précision. Néanmoins, d'autres limites apparaissent tel que l'optimisme du filtre et le problème de convergence prématurée.

Encouragés par les résultats en précision, les travaux ont donc continuer dans le même sens qui est l'hybridation. Le but est celui de corriger les lacunes du SPF. Une première tentative est d'introduire un pourcentage de particules perturbatrices qui empêchent l'essaim de trop se concentrer, mais l'amélioration n'apporte pas de garantie de non convergence prématurée. L'idée qui donne naissance à l'OKPS vient de l'EKF. Le filtre de Kalman étendu, dote chaque estimation (prédiction ou correction) d'une mesure de vraisemblance sous forme de matrice de variance/covariance, cette mesure est ensuite employée comme une note d'auto-diagnostic afin de faire un compromis entre la prédiction et la correction. Ce mécanisme d'auto-régulation, une fois intégré aux particules pourrait apporter l'information primordiales aux particules afin d'échanger efficacement et éviter en même temps l'explosion et la convergence prématurée de l'essaim.

L'OKPS affiche donc de vraies qualités de filtre réactif (à partir du PF) et coopératif (à partir de la PSO et régulé par l'auto-diagnostic). L'OKPS fait une fusion multi-approches qui comme pour la fusion multi-sources, tire le meilleure de chaque information afin de rendre un meilleure résultat que celui obtenu avec chaque élément seul. Cette fusion se conclue par une fonction de fitness qui fait office de fonction de vraisemblance adaptative finale. Cette fonction se base sur les auto-diagnostics des particules, sur les mesures capteurs et leurs incertitudes afin de rendre une note finale à chaque particule. Note qui sera l'élément de base dans l'influence de la particule à la conception de l'estimé fusionnée.

Une fois les bases théoriques de chaque approche posées et implémentées parallèlement sous Matlab et C/C++ "RtMaps", les tests sont donc effectués sur des bases de données réelles issues de collectes de données lors des scénarios de conduite effectués avec le véhicule instrumenté du laboratoire IFSTTAR/LIVIC. Le rendement des filtres en positionnement sur les pistes par rapport à celui de la référence RTK est tout à fait analysable à l'œil grâce à un affichage temps réel projeté sur les plans des pistes de Satory et permet donc de préalablement confirmer le bon fonctionnement des approches et une localisation non divergente mais ne permet pas d'en dire plus. Il convient donc de sélectionner ou concevoir des critères d'analyse de performance afin de faire une analyse objective et scientifiquement fondée.

Le défi à surmonter dans la mise en œuvre des critères de performances est que les critères doivent être adaptés à toutes les approches sachant que nous avons affaire à des approches souches et des approches hybrides incluant des méthodes non-issu du filtrage bayésien. Tout d'abord, il convient de fixer les catégories des performances dans lesquelles il fallait ensuite développer et/ou utiliser des critères. Les

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

performances sont finalement jugées selon trois grands axes de critères : précision, consistance et robustesse. Chacun de ces axes a fait l'objet d'études de critères multiples adaptés à l'application d'égo-localisation de véhicules routier. Puis un tri sélectif a été fait afin de sélectionner les bons critères qui permettront de juger les performances de toutes les approches étudiées à la fois. Le chapitre 6 *Protocole de test et de validation des estimateurs* dresse les détails de cette sélection.

Une fois les critères sélectionnés et les jeux de données des scénarios de conduite disponibles, les tests peuvent avoir lieu. Les tests sont faits en "re-jeu temps réel" par lecture des données réelles enregistrées suivant leurs marqueurs temporels. Les tests sont effectués sous un environnement de prototypage dédié aux applications automobile appelé "RtMaps". Une fois les tests finalisés sous RtMaps, les fichiers de résultats enregistrés sont analysés sous Matlab suivant les différents critères sélectionnés afin de classer les performances des filtres en matière de précision, consistance et robustesse.

L'OKPS se distingue alors par ses performances dans l'ensemble des tests et la conclusion qui peut être tirée des tests effectués est que l'OKPS est la meilleure approche à adopter en cas de perturbations du signal et lors de multi-trajets GPS comme dans le cas des canyons urbains lors de la conduite en milieu urbain haut et dense. L'EKF et le PF apportent, à peu de choses près, les mêmes résultats et restent intègres dans tout les cas de figures. Le SPF quant à lui, affiche de bons résultats en précision et semble plus adapté aux cas des conditions dégradées mais souffre toujours d'un problème d'optimisme même après intégration de 90% de particules perturbatrices. En résumé, pour une application d'égo-localisation routière l'utilisateur a le choix entre l'OKPS, l'EKF et le PF pour les cas classiques avec peu de perturbations, ce choix se fera aussi selon la puissance de calcul à disposition car le PF avec un nombre de particules plus important peut s'avérer plus efficace que l'EKF en cas de perturbation et plus précis dans le cas général. Dans le cas de conditions dégradées, de GPS de mauvaise qualité et de forts changements de dynamique de véhicule l'OKPS est l'approche la plus recommandée.

Pour un gain optimal en matière de puissance de calcul et de temps d'exécution, un système complet comptant un EKF et un OKPS travaillant indépendamment et s'activant selon le cas de figure serait le système le plus optimisé pour un utilisateur visant à faire de l'égo-localisation routière urbaine et extra-urbaine comme en autoroute. Les estimés de l'EKF et de l'OKPS étant semblable, le basculement d'une approche à l'autre ne demanderait aucune adaptation mais nécessiterait un léger sur-dimensionnement en puissance de calcul afin de pouvoir gérer une phase de recouvrement des deux approches fonctionnant simultanément pendant le cycle précédant le basculement.

Ce type d'application complète reste en perspectives et nécessite la réalisation d'autres travaux avant d'envisager un tel concept. L'approche IMM présentée dans les travaux de Ndjeng est une approche aussi robuste que l'OKPS. L'IMM a en plus une fonction de mise à jour des vraisemblances en phase de prédiction, ce qui n'est pas le cas de l'OKPS. Un test comparant les performances de ces deux approches serait un tournant en matière de perspective d'applications. Car si l'OKPS est censé être moins précis que l'IMM dans les cas de manœuvres mélangeant marche arrière et marche avant tel que les manœuvres de parking, il n'est pas supposé être moins efficace lors de masquage et perturbations GPS. Une amélioration de l'OKPS visant à intégrer une mise à jour en phase de prédiction serait aussi une bonne continuité des travaux actuels. Il est aussi possible, d'envisager d'autres sources d'informations telles que d'autres capteurs embarqués ou des sources externes sur l'environnement par des balises ou de la cartographie précise. Tout dépendra des avancements technologiques et de la disponibilité de ces sources dans le futur. Des améliorations mineurs pourraient être apportées en étudiant d'autres types de topologies de voisinage des particules et d'autres conceptions d'essaim, tel que TRIBES [CCS09], une organisation de l'essaim en tribus adaptatives qui rendrait le nombre de particules adaptatif et qui permettrait d'employer un modèle d'évolution véhicule différent dans chaque tribu par exemple. L'OKPS pourrait aussi être adapté à d'autres applications dans le domaine de la fusion de données, autres que celui de localisation-automobile ou même autre que la localisation complètement, cela sera la conséquence des retours des publications scientifiques associées aux travaux de cette thèse.

Chapitre 9

Annexe

Sommaire

9.1	Présentation du véhicule instrumenté du LIVIC	145
9.2	Capteurs utilisés	147
9.2.1	GNSS (GPS/GLONASS/GALILEO)	147
9.2.2	INS (Centrale inertielle)	149
9.2.3	L'Odomètre	150
9.2.4	Encodeur de braquage des roues	151
9.3	Calibrage PSO	151

9.1 Présentation du véhicule instrumenté du LIVIC

Le LIVIC dispose d'une petite flotte de véhicules instrumentés. Comme le montre la figure 9.1, ces véhicules sont équipés d'un ensemble de capteurs proprioceptifs et extéroceptifs. Les véhicules sont aussi équipés d'ordinateurs embarqués faisant tourner des programmes dédiés pour les tests des applications développées sous RtMaps ainsi que pour l'enregistrement des données capteurs dans l'ordre de leur arrivée en temps réel de façon à conserver des jeux de données réels pour effectuer des tests sous ordinateur sans avoir à refaire le scénario de conduite sur les pistes de Satory ou sur la route pour chaque test. Ces véhicules sont aussi utilisés pour des démonstrations de toutes les nouveautés développées au LIVIC en matière d'aide à la conduite




FIGURE 9.1 – Véhicules équipés du LIVIC [Réalisation par Dr D.GRUYER]

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

9.2 Capteurs utilisés

Les capteurs utilisés dans notre application d'égo-localisation sont un GPS bas coût, un odomètre, un gyroscope intégré dans une centrale inertielle et un encodeur d'angle de braquage. Ces capteurs sont présentés en détails dans la thèse de Ndjeng. Les notions suivantes sont ici pour donner idée au lecteur des informations fournies par ces capteurs. Toute personne intéressée par les détails de fonctionnement de ces capteurs peut se référer en premier lieu à [NN09] et aux datasheet des capteurs pour plus de détails.

9.2.1 GNSS (GPS/GLONASS/GALILEO)

Les systèmes de positionnement et de navigation par satellites se basent sur la détermination de la position par principe de triangulation. Cette technique nécessite la présence et la bonne visibilité d'au moins quatre satellites afin de mesurer les distances entre le récepteur et chaque satellite. Il existe deux systèmes de positionnement par satellites opérationnel et deux autres en cours de développement. Les deux systèmes opérationnels sont le GPS NAVSTAR américain et le système GLONASS russe. Le système GALILEO européen et Beidou chinois sont quand à eux en cours de déploiement.

Le système GPS mis en œuvre par les américains est originalement un système né d'un programme militaire datant des années 70. Ce système est partiellement ouvert maintenant de manière publique mais reste sous le contrôle des autorités américaines qui gère le cryptage de certaine information et la disponibilité du signal. C'est cette dépendance qui pousse chaque région ou pays à développer son propre système GNSS. Le système GPS se compose en tout de 24 satellites NAVSTAR sur 6 orbites inclinés de 55° et situées à une altitude de 20184 km. La figure 9.2(a) montre la composition de ce système et la répartition des satellites NAVSTAR. En complément aux satellites, le système GPS comporte 5 stations au sol et représente pour le moment le système de géolocalisation le plus utilisé dans le monde de par sa gratuité. Le GPS fournit une localisation d'une précision de l'ordre de 10 m à 2σ , il ne couvre pas toutes les zones géographiques et la qualité du signal est volontairement limitée par ses administrateurs.

Deux méthodes de positionnement peuvent être distinguées avec les GNSS : La première est le positionnement absolu, elle consiste en une simple triangulation à partir des données émises par les satellites visibles. La deuxième méthode est celle du positionnement relatif, elle utilise une station basée au sol dont la position est parfaitement connue. Cette station permet de transmettre des corrections aux satel-

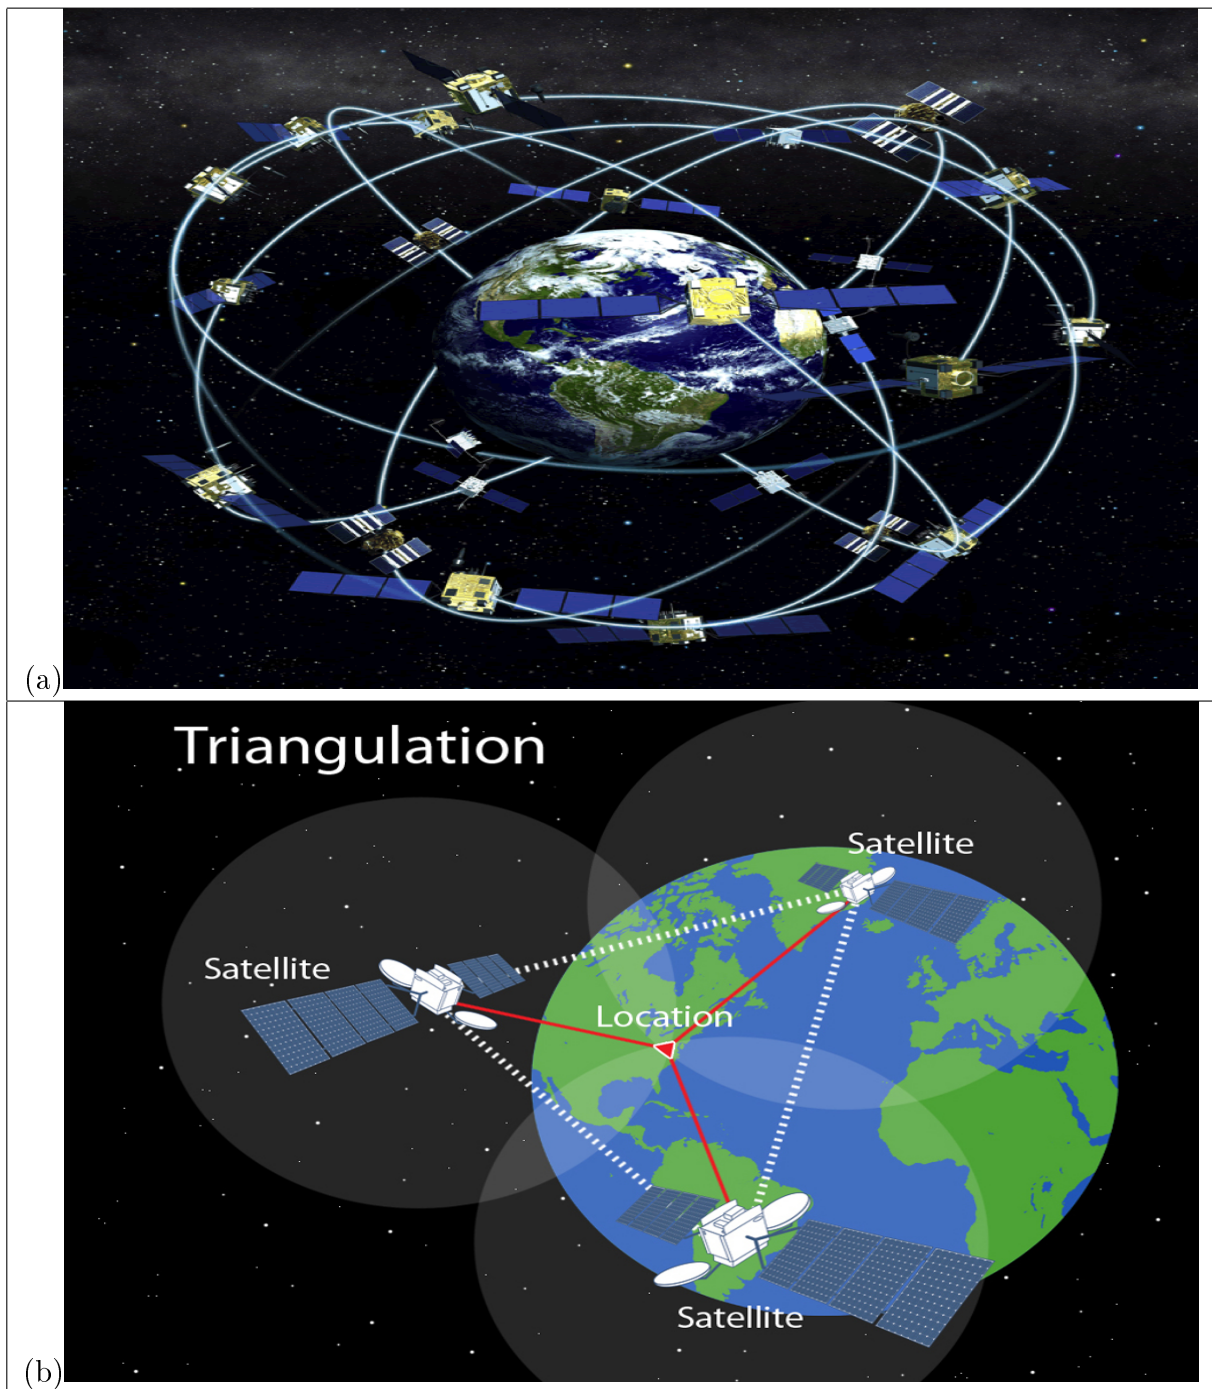


FIGURE 9.2 – Constellation des satellites GPS et principe de triangulation

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

lites, corrigeant les erreurs de triangulation, ainsi permettant d'estimer et de corriger les erreurs afin d'avoir un positionnement plus précis.

La position des satellites $X_s^i = \{x_s^i, y_s^i, z_s^i\}$ et les pseudo-distances satellite-récepteur D_i étant connues. La position du récepteur $X_r = \{x_r, y_r, z_r\}$ est alors obtenue suivant le principe de triangulation décrit par la figure 9.2(b) et par le système d'équations 9.1.

$$\sqrt{(x_s^i - x_r)^2 + (y_s^i - y_r)^2 + (z_s^i - z_r)^2} = D_i \quad (9.1)$$

La qualité du positionnement peut être altérée par la constellation des satellites et leur disposition, l'élévation des satellites, les problèmes d'émission et de réception du signal, les erreurs due à la réfraction dans l'atmosphère et celles dues aux multi-trajets.

9.2.2 INS (Centrale inertielle)

La localisation inertielle utilise des mesures issues d'accéléromètres et de gyroscopes afin de déterminer le positionnement. Ces données sont employées pour estimer l'évolution du mobile (véhicule) à partir d'un point de départ connu afin de déterminer sa position et son orientation actuelles. Les capteurs inertiels sont utilisés dans un grand nombre d'études dans les domaines touchant à la navigation en milieu aérien, maritime et terrestre. Les avancées technologiques ont permis la fabrication de capteurs inertiels MEMS¹, ces dispositifs sont de petites tailles, légers et économiques.

Les mesures nécessaires à la localisation inertielle sont fournies par des capteurs contenus dans une IMU². L'IMU est un dispositif composé de trois accéléromètres et de trois gyroscopes fournissant les accélérations et les vitesses angulaires autour de chaque axe. L'INS³ est un système de navigation qui associe l'IMU à un calculateur intégrateur. En partant des données accélérométriques et tout en connaissant leurs orientations spatiales, la localisation est obtenue par les équations suivantes :

$$\begin{cases} \text{vitesse } v = & \int a \, dt \\ \text{position } p = & \int v \, dt \\ \text{orientation } \psi = & \int \omega \, dt \end{cases} \quad (9.2)$$

1. MEMS : Micro Electronic Mechanical Systems

2. IMU : Inertial Measurement Unit

3. INS : Inertial Navigation System

Le gyroscope est le capteur qui mesure la vitesse de rotation du véhicule suivant l'axe où il est monté. Plus de détails sur les technologies des gyroscopes et la localisation à base de capteurs proprioceptifs sont disponible dans les ouvrages spécialisés ou dans des thèses telle que [NN09]. L'équation 9.3 décrit le modèle générale d'ordre 1 d'une sortie de gyroscope.

$$\omega_{out} = (1 + SF_{\omega})\omega_{true} + b_{\omega} + \eta_{\omega} \quad (9.3)$$

avec : ω_{out} : La vitesse angulaire en sortie

SF_{ω} : Le facteur d'échelle affectant la vitesse de rotation

ω_{true} : La vraie vitesse angulaire mesurée par le capteur

b_{ω} : Le terme caractérisant le biais

η_{ω} : Le bruit estimé du gyroscope

Trois type de technologies gyroscope se distinguent : les FOG⁴, les RLG⁵ et les gyroscope à conception MEMS.

9.2.3 L'Odomètre

La localisation basée sur l'odométrie consiste à intégrer les rotations des roues du véhicule déduisant de cela la vitesse du véhicule permettant une estimation de l'état courant du véhicule à partir d'un état de départ connu [Bon05].

Montés sur les roues des véhicules, les odomètres mesurent le nombre de tour par période effectué par les roues à l'aide de codeurs incrémentaux généralement optiques. La précision des mesures dépend de la résolution des codeurs. L'odométrie différentielle, permet de calculer le changement d'orientation du véhicule à partir de la différence de distance parcourue par la roue de chaque coté en supposant un glissement négligeable.

L'odométrie a l'avantage d'être accessible et facile à mettre en œuvre, la cadence d'acquisition de mesures est très élevée et la précision à court terme est bonne. Cependant, l'erreur à long terme devient ensuite importante. Effectivement, l'odométrie affiche une dérive à cause des erreurs dues au patinage et aux glissements des roues qui se cumulent au fil des mesures. Les erreurs cumulatives affectent la distance parcourue et l'angle d'orientation mesurés mais n'altère pas la mesure de vitesse. Afin d'avoir un positionnement absolu de bonne qualité, il est donc nécessaire d'associer l'odométrie à un capteur externe tel que le GPS.

4. FOG : Fiber Optic Gyro

5. RLG : Ring Laser Gyro

9.2.4 Encodeur de braquage des roues

Le capteur de braquage des roues ou du volant est conçu sur le même principe que l'odomètre. Ce capteur est un dispositif d'encodage de rotation précis intégré au volant généralement comme le montre les figures 9.3 (a) et (b). Ce capteur transmet sur le Bus CAN de la voiture la donnée mesurée qui est l'angle que forment les roues par rapport au châssis de la voiture.

Les grandeurs transmises par les capteurs proprioceptifs précédents sont en pratique employée dans un modèle cinématique d'évolution du véhicule qui sert à fusionner ces différentes mesures afin de calculer l'évolution en position et en orientation du véhicule entre deux instants. Cela permet de fournir la localisation actuelle du véhicule par rapport à un point de départ connu.

9.3 Calibrage PSO

Afin d'effectuer un calibrage des paramètres PSO, des tests avec plusieurs paramètres ont été effectués. Les paramètres à calibrer dans ces tests ont été : Le nombre de particule N , Le seuil de rééchantillonnage N_{th} et le facteur d'inertie W .

Le calibrage a été donc effectué en trois étapes, chaque étape consistait à fixer deux paramètres et faire varier le troisième et analyser le comportement de la localisation à base de PSO de manière à définir les meilleures valeurs de ces paramètres. Les tests ont été accomplis de manière répétée de façon à garantir une moyenne statistique, les tableaux présentés par la suite résument les tests de calibrage des paramètres PSO.

1. Calibrage du nombre de particules N

Les paramètres fixes sont $N_{th} = 0.85$; $W = 0.5$ pour le tableau 9.1.


La PSO suit le GPS de plus en plus et c'est ce qui fait croître l'erreur. Il reste tout de même clair que le nombre de particule n'a pas une grande influence sur l'erreur.

2. Calibrage du facteur d'inertie W


Les paramètres fixe sont $N = 100$; $N_{th} = 0.85$ pour le tableau 9.2.

3. Calibrage du seuil de rééchantillonnage N_{th}

Les paramètres fixe sont $N = 100$; $W = 0.7$ pour le tableau 9.3.



(a)



(b)

FIGURE 9.3 – Encodeur d'angle de braquage

Localisation multi-hypothèses pour l'aide à la conduite : conception d'un filtre "réactif-coopératif"

Nb Particules	Erreur en X (m)			Erreur en Y (m)			Time (s)		Commentaires
	Test1	Test2	Test3	Test1	Test2	Test3			
20	1.931890			4.250106			0.00834185817763		Sortie non lisse quelques sorties de piste (5-10m)
30	1.028801			2.409166			0.00811160236318		Sortie non lisse quelques sorties de piste (4-6m)
40	1.023970			2.405644			0.00846904717758		
50	1.051451	1.022908	1.023963	2.400331	2.382355	2.392474	0.00911439471045	0.00905097158892	Sortie non lisse quelques sorties de piste (3-4m)
100	1.030860	1.041428	1.039918	2.422863	2.423949	2.430943	0.01434919822007	0.01429187899567	Sortie non lisse rares sorties de piste (2-3m) 1 ^{er} test sans sorties présence de sauts
150	1.055066	1.041704	1.034708	2.455368	2.436735	2.418449	0.02106856754437	0.02111386967611	Assez lisse Quelques sauts Rares sorties (1- 2m)
200	1.047303	1.033573	1.039858	2.447930	2.422734	2.446064	0.02790872292940	0.02792953085321	sortie lisse Suit le GPS Pas de sorties Rares sauts
250	1.032362	1.044479	1.050017	2.419554	2.442437	2.455568	0.03470562011030	0.03464931693643	Sortie lisse Suit le GPS Quelques sauts entre le RTK et le GPS
300	1.048010	1.047805	1.036582	2.449883	2.455517	2.442739	0.04230640980402	0.04273021564483	Pas de sorties Sortie lisse Suit le GPS Pas de sauts Pas de sorties
350	1.044059	1.051120	1.047307	2.446617	2.450066	2.450263	0.04931620894140	0.04885469885581	Sortie lisse Suit le GPS Pas de sauts Pas de sorties
400	1.042524	1.039686	1.046051	2.439681	2.432326	2.447758	0.05551617773550	0.05655116034133	
1000		1.054196				2.462083		0.13976038952467	

TABLE 9.1 – PSO : Calibrage du nombre de particules N

w	Erreur en X (m)			Erreur en Y (m)			Time (s)			Commentaires
	Test1	Test2	Test3	Test1	Test2	Test3				
0	1.029295	1.034704	1.021952	2.410799	2.393944	2.369401	0.01455794566560	0.01483662690647	0.01460961598232	Assez lisse rares sorties quelques sauts
0.1	1.070723	1.081651	1.025094	2.469755	2.528398	2.388438	0.01516301432300	0.01516617899726	0.01433757469766	moins lisse quelques sorties quelques sauts
0.2	1.032592	1.009867	1.045245	2.412644	2.399612	2.440826	0.01446395294386	0.01579607937848	0.01428874668291	Moins de sorties quelques sauts
0.3	1.019423	1.039725	1.026380	2.398349	2.439519	2.392518	0.01430708131970	0.01478190115824	0.01461826023799	Assez lisse Pas de sorties quelques sauts
0.4	1.026361	1.036888	1.037789	2.397807	2.411252	2.420314	0.01433420700877	0.01431654680228	0.01432606218270	Assez lisse Pas de sorties Moins de sauts
0.5	1.020865	1.064513	1.023595	2.398873	2.474238	2.391392	0.01487187528559	0.01556227577055	0.01420879895769	Assez lisse Pas de sorties
0.6	1.031132	1.056248	1.055927	2.421581	2.462001	2.446375	0.01421602298230	0.01422605385144	0.01418978817014	Plus lisse Pas de sorties Rares sauts
0.7	1.052831	1.055376	1.035654	2.465859	2.455580	2.418771	0.01440650498549	0.01418717373209	0.01427598769038	lisse Pas de sorties Très Rares sauts
0.8	1.044567	1.062430	1.053888	2.448561	2.474688	2.461306	0.01420481168987	0.01528010359107	0.01424812075160	Assez lisse Pas de sorties Très Rares sauts
0.9	1.089407	1.110839	1.072888	2.533130	2.539300	2.477748	0.01630314805976	0.01426104424515	0.01423394235950	non lisse Pas de sorties
1	2.147309	3.501729	2.121055	4.101449	5.911058	4.578817	0.01425159890836	0.014233161681115	0.01422149913162	Estimation catastrophique Explosion de l'essai

TABLE 9.2 – PSO : Calibrage du facteur d'inertie W

N th	Erreur en X (m)			Erreur en Y (m)			Time (s)			Commentaires
	Test1	Test2	Test3	Test1	Test2	Test3				
0	1.059001	1.058464	1.068613	2.472187	2.476798	2.490159	0.014443198643393	0.01400849691947	0.01432308480005	Lisse Ellipse d'incertitude grande
0.05	1.056352	1.054326	1.065084	2.465459	2.480763	2.485142	0.014394555504394	0.01440304206080	0.01439536695647	Lisse Ellipse d'incertitude grande
0.1	1.055999	1.053854	1.044772	2.468899	2.473855	2.446088	0.01529152672600	0.01450645137566	0.01724443722920	
0.15	1.037620	1.072532	1.068305	2.437636	2.500092	2.494256	0.01503736043590	0.01521970754216	0.01460083723865	Rares sauts Ellipse d'incertitude moyenne
0.2	1.044533	1.057732	1.033951	2.439869	2.481528	2.407637	0.01537403781265	0.01456327227175	0.01468830370068	
0.3	1.046280	1.072294	1.053665	2.449762	2.489809	2.444156	0.01462801628418	0.01612436586316	0.01449735945910	Quelques sauts
0.4	1.048495	1.039339	1.050756	2.444366	2.434984	2.463399	0.01640756775073	0.014440948956400	0.01437218857537	
0.5	1.026825	1.035349	1.049695	2.399092	2.399617	2.439907	0.014386642677235	0.01437928465327	0.01436026786400	Quelques sorties (1-2m)
0.6	1.037971	1.028644	1.036180	2.441217	2.421664	2.449608	0.01480393958894	0.01659416710263	0.01439215213668	
0.7	1.042450	1.053249	1.039093	2.442176	2.442430	2.432463	0.01435789079907	0.01430763467629	0.01436516420406	Lisse Suit le GPS
0.8	1.041249	1.044943	1.044361	2.441442	2.437671	2.436871	0.01433339053193	0.01433862627642	0.01428039152251	
0.9	1.060875	1.039788	1.042492	2.469812	2.443151	2.449868	0.01427585705462	0.01528405147842	0.01520755409949	
1	1.056090			2.458711			0.01425886454252			Se colle de plus en plus au GPS

TABLE 9.3 – PSO : Calibrage du seuil de rééchantillonnage N_{th}

Bibliographie

A

- [abE09] G. a b Evers. An automatic regrouping mechanism to deal with stagnation in particle swarm optimization. Master's thesis, The University of Texas - Pan American, Department of Electrical Engineering., 2009.
- [ABGL13] A.R. Ahmed Bacha, D. Gruyer, and A. Lambert. A robust hybrid multisource data fusion approach for vehicle localization. *Scientific Research Publish (SCIRP) Positioning*, 4(4) :271–281, November 2013.
- [ABGM13] A.R. Ahmed Bacha, D. Gruyer, and S. Mammar. A new robust cooperative-reactive filter for vehicle localization : The extended kalman particle swarm. In *Intelligent Vehicles Symposium (IV), IV 2013 IEEE*, pages 195–200, 2013.
- [Abu05] Iyad Abuhadrous. *Système embarqué temps réel de localisation et de modélisation 3D par fusion multi-capteur*. PhD thesis, École Nationale Supérieure des Mines de Paris, 2005.
- [AF70] G. A. Ackerson and K. S. Fu. On state estimation in switching environments. *IEEE Transaction on Automatic Control*, AC(15) :10–17, 1970.
- [AIK91] A. Averbuch, S. Itzikowitz, and T. Kapon. Radar target tracking - viterbi versus imm. *IEEE Trans. on Aerosp. Electronic Systems*, AES-27(3) :550–563, May 1991.
- [ANL03] I. Abuhadrous, F. Nashashibi, and C. Laugeau. 3-d land vehicle localization : a real-time multi-sensor data fusion approach using rtmmaps. In *International Conference on Advanced Robotics*, pages 71–76, Coimbra, Portugal, 2003.

- [AUBM10] Jamshaid Ali and M R Ullah Baig Mirza. Performance comparison among some nonlinear filters for a low cost sins/gps integrated solution. *Nonlinear Dynamics*, pages 1–12, 2010.

B

- [Bad09] Boualem Badji. *Caractérisation du comportement non linéaire en dynamique du véhicule*. PhD thesis, Université de Technologie de Belfort-Montbéliard, 2009.
- [Bay63] T. Bayes. An essay towards solving a problem in the doctrine of chances. pages 53 :370–418, 1763.
- [BB08] Dan Bratton and Tim Blackwell. A simplified recombinant pso. *Journal of Artificial Evolution and Applications*, 2008 :14, 2008.
- [BBM09] L. Bazzani, D. Bloisi, and V. Murino. A comparison of multi hypothesis kalman filter and particle filter for multi-target tracking. In *Performance Evaluation of Tracking and Surveillance workshop at CVPR*, pages 47–54, 2009.
- [BBS88] H. A. P. Blom and Y. Bar-Shalom. The interacting multiple model algorithm for systems with markovian switching coefficients. *IEEE Tans. on Aut. Control*, 33(8) :780–783, 1988.
- [BDH00] Miodrag Bolić, Petar M Djurić, and Sangjin Hong. Resampling algorithms for particle filters : A computational complexity perspective. *EURASIP Journal on Advances in Signal Processing*, 2004(15) :2267–2277, 1900.
- [BDW95] Billur Barshan and Hugh F Durrant-Whyte. Evaluation of a solid-state gyroscope for robotics applications. *Instrumentation and Measurement, IEEE Transactions on*, 44(1) :61–67, 1995.
- [BDW06] Tim Bailey and Hugh Durrant-Whyte. Simultaneous localization and mapping (slam) : Part ii. *IEEE Robotics & Automation Magazine*, 13(3) :108–117, 2006.
- [BFHS96] W. Burgard, D. Fox, D. Hennig, and T. Schmidt. Estimating the absolute position of a mobile robot using position probability grids. In *Proc. 14th National Conference on Artificial Intelligence (AAAI'96)*, pages 896–901, Aug 1996.
- [BL92] D BOSQ and JP LECOUTRE. Analyse et prévision des séries chronologiques : méthodes paramétriques et non paramétriques-editions masson, 1992.

- [BLF⁺09] Philippe Bonnifait, Jean Laneurit, Clément Fouque, Gérald Dherbomez, et al. Multi-hypothesis map-matching using particle filtering. In *Proceedings of the 16th World Congress for ITS Systems and Services*, pages 1–8, 2009.
- [Blo84] H. A. Blom. An efficient filter for abruptly changing systems. *Proc. 23rd Conf. Decision and Control*, pages 656–658, 1984.
- [Bon97] P. Bonnifait. *Precise Localization in Position and Attitude of Outdoor Slow Speed Mobile Robots*. PhD thesis, University of Nantes, 1997.
- [Bon05] Philippe Bonnifait. *Contribution à la localisation dynamique d'automobiles. Application à l'aide à la conduite*. PhD thesis, Université de Technologie de Compiègne, 2005.
- [BP99] S. Blackman and R. Popoli. *Multitarget-Multisensor Tracking : Advanced Applications*. Artech House, Norwood,MA, 1999.
- [BS90] Y. Bar-Shalom. *Multitarget-Multisensor Tracking : Advanced Applications*. Artech House, Norwood,MA, 1990.
- [BS92] Y. Bar-Shalom. *Multitarget-Multisensor Tracking : Applications and Advances*, volume II. Artech House, Norwood, MA, 1992.
- [BSL93] Y. Bar-Shalom and X. R. Li. *Estimation and Tracking : Principles, Techniques, and Software*. Artech House, Boston, MA, 1993. Reprinted by YBS Publishing, 1998.
- [BVA07] Alec Banks, Jonathan Vincent, and Chukwudi Anyakoha. A review of particle swarm optimization. part i : background and development. *Springer Science, Business Media*, 17 July 2007.

C

- [CA78] C. B. Chang and M. Athans. State estimation for discrete systems with switching parameters. *IEEE Transaction on Aerospace and Electronic Systems*, AES-14(5) :418–425, May 1978.
- [CAL08] Guillaume CALAS. Optimisation par essaim de particules <http://guillaume.calas.free.fr/publications.html>. 25 Juin 2008.
- [CBWC12] Zhi-min CHEN, Yu-ming BO, Pan-long WU, and Qin-xin CHEN. A new hybrid algorithm for particle filtering and its application to radar target tracking. *Acta Armamentarii*, 1 :013, 2012.

- [CCL02] C. A. Coello Coello and M. S. Lechuga. Mopso : a proposal for multiple objective particle swarm optimization. In *IEEE Congress on Evolutionary Computation*, volume 02, pages 1051–1056, 2002.
- [CCS08] Maurice Clerc, Yan Cooren, and P Siarry. Optimisation par essaim particulaire améliorée par hybridation avec un algorithme d'estimation de distribution. In *Annales des doctorales MACS*, volume Volume 5, N1, pages 21–27, 2008.
- [CCS09] Yann Cooren, Maurice Clerc, and Patrick Siarry. Performance evaluation of tribes, an adaptive particle swarm optimization algorithm. *Swarm Intelligence*, 3(2) :149–178, 2009.
- [CD01] Anthony Carlisle and Gerry Dozier. An off-the-shelf pso. In *Proceedings of the workshop on particle swarm optimization*, volume 1, pages 1–6. Indianapolis, 2001.
- [CD02] Dan Crisan and Arnaud Doucet. A survey of convergence results on particle filtering methods for practitioners. *Signal Processing, IEEE Transactions on*, 50(3) :736–746, 2002.
- [CGDM10] Javier Civera, Oscar G Grasa, Andrew J Davison, and JMM Montiel. 1-point ransac for extended kalman filtering : Application to real-time structure from motion and visual odometry. *Journal of Field Robotics*, 27(5) :609–631, 2010.
- [Che13] Ding X.-M. & Shen H.-B. Cheung, N. J. Optifel : A convergent heterogeneous particle swarm optimization algorithm for takagi-sugeno fuzzy modeling. *IEEE Transactions on Fuzzy Systems*, 2013.
- [CK02] Maurice Clerc and James Kennedy. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. *Evolutionary Computation, IEEE Transactions on*, 6(1) :58–73, 2002.
- [Cle03] Maurice Clerc. Optimisation par essaim particulaire-tutoriel pour oep. 2003.
- [COO08] Yan COOREN. *Perfectionnement d'un algorithme adaptatif d'Optimisation par Essaim Particulaire. Applications en Génie Mécanique et en Électronique*. PhD thesis, Université Paris 12, 2008.
- [CW90] I.J. Cox and G.T. Wilfong. *Autonomous Robot Vehicles*, chapter The Kalman Filter : An Introduction to Concept, pages 194–204. Springer-Verlag, New York, 1990.

D

- [Das14] Belur V. Dasarathy. A special issue on information fusion in hybrid intelligent fusion systems. *Information Fusion*, 16(0) :1 –, 2014. Special Issue on Information Fusion in Hybrid Intelligent Fusion Systems.
- [DC05] Randal Douc and Olivier Cappé. Comparison of resampling schemes for particle filtering. In *Image and Signal Processing and Analysis, 2005. ISPA 2005. Proceedings of the 4th International Symposium on*, pages 64–69. IEEE, 2005.
- [DH98] Zhen Ding and Lang Hong. A distributed imm fusion algorithm for multi-platform tracking. *Signal Processing*, 64 :167–176, 1998.
- [DLCH06] T. S. Dao, K. Y. K. Leung, C. M. Clark, and J. P. Huissoon. Co-operative lane-level positioning using markov localization. In *IEEE Intelligent Transportation Systems Conference*, pages 1006–1011, Toronto, Canada, 2006.
- [DLH98] O. E. Drummond, X. R. Li, and C. He. Comparison of various static multiple-model estimation algorithms. In *SPIE Conference on Signal and Data Processing of Small Targets*, pages 510–527, 1998.

E

- [EC03] S. C. Esquivel and C. A. Coello Coello. On the use of particle swarm optimization with multimodal functions. *IEEE Congress on Evolutionary Computation*, pages 1130–1136, 2003.
- [EEB07] Wesam Elshamy, Hassan M Emara, and Ahmed Bahgat. Clubs-based particle swarm optimization. In *Swarm Intelligence Symposium, 2007. SIS 2007. IEEE*, pages 289–296. IEEE, 2007.
- [ES00] Russ C Eberhart and Yuhui Shi. Comparing inertia weights and constriction factors in particle swarm optimization. In *Evolutionary Computation, 2000. Proceedings of the 2000 Congress on*, volume 1, pages 84–88. IEEE, 2000.
- [ES01] Russell C Eberhart and Yuhui Shi. Particle swarm optimization : developments, applications and resources. In *Evolutionary Computation, 2001. Proceedings of the 2001 Congress on*, volume 1, pages 81–86. IEEE, 2001.

F

- [FBDT99] D. Fox, W. Burgard, F. Dellaert, and S. Thrun. Monte carlo localization : Efficient position estimation for mobile robots. In *Proc. National Conference on Artificial Intelligence (AAAI'99)*, 1999.
- [FBT99] D. Fox, W. Burgard, and S. Thrun. Markov localization for mobile robots in dynamic environments. *Journal of Artificial Intelligence Research*, 11, 1999.
- [Fra02] van den Bergh Frans. *An analysis of particle swarm optimizers*. PhD thesis, University of Pretoria, South Africa, 2002.
- [FS12] Friedrich Fraundorfer and Davide Scaramuzza. Visual odometry : Part ii : Matching, robustness, optimization, and applications. *Robotics & Automation Magazine, IEEE*, 19(2) :78–90, 2012.
- [FTX07] Zheng Fang, Guo-feng Tong, and Xin-he Xu. Particle swarm optimized particle filter. 22(3) :273, 2007.

G

- [GB05] AMADOU GNING and PHILIPPE BONNIFAIT. Fusion de données redondantes avec une technique ensembliste atteignant la consistance globale. 2005.
- [GBFK98] J. S. Gutmann, W. Burgard, D. Fox, and K. Konolige. An experimental comparison of localization methods. In *Int. Conf. On Intelligent Robots and Systems (IROS)*, 1998.
- [GGL05] R. Giroux, R. Gourdeau, and R. Landry. Extended kalman filter implementation for low-cost ins/gps integration in a fast prototyping environment. In *Symposium on Navigation of the Canadian Navigation Society*, pages 1–11, Toronto, Canada, 2005.
- [GGLV12] Jorge Godoy, Dominique Gruyer, Alain Lambert, and Jorge Villagra. Development of an particle swarm algorithm for vehicle localization. In *IEEE Intelligent Vehicles Symposium*, pages 1114–1119, June 3-7 2012.
- [Gut02] J. S. Gutmann. Markov-kalman localization for mobile robots. In *Int. Conf. on Pattern Recognition (ICPR)*, 2002.
- [GWN01] J. S. Gutmann, T. Weigel, and B. Nebel. A fast, accurate, and robust method for self-localization in polygonal environments using

laser range finders. *Advanced Robotics Journal*, 14(8) :651–668, 2001.

H

- [Han70] JE Handschin. Monte carlo techniques for prediction and filtering of non-linear stochastic processes. *Automatica*, 6(4) :555–563, 1970.
- [HNT10] Ramazan Havangi, Mohammad Ali Nekoui, and Mohammad Teshnehlab. A multi swarm particle filter for mobile robot localization. *International Journal of Computer Science*, 7(3) :15–22, 2010.
- [Hol04] Jeroen D Hol. Resampling in particle filters. 2004.
- [HSG06] Jeroen D. Hol, Thomas B. Schön, and Fredrik Gustafsson. On resampling algorithms for particle filters. In *Nonlinear Statistical Signal Processing Workshop*, 2006.

I

- [IMN01] L. Iocchi, D. Mastrantuono, and D. Nardi. A probabilistic approach to hough localization. In *Int. Conf. on Robotics and Automation (ICRA), Seoul, Korea*, 2001.
- [IX00] K. Ito and K. Xiong. Gaussian filters for nonlinear filtering problems. *IEEE Transaction on Automatic Control*, 45(5) :910–927, 2000.

J

- [JC09] Dah-Jing Jwo and Shun-Chieh Chang. Particle swarm optimization for gps navigation kalman filter adaptation. *Aircraft Engineering and Aerospace Technology*, 81 Iss : 4 :343 – 352, 2009.
- [JG71] A. G. Jaffer and S. C. Gupta. On estimation of discrete processes under multiplicative and additive noise conditions. *Information Science*, 3, 1971.
- [JU96] S. J. Julier and J.K. Uhlmann. A general method for approximating nonlinear transformation of probability distribution. Technical report, University of Oxford, 1996.
- [JU97] S. J. Julier and J.K. Uhlmann. A new extension of the kalman filter to nonlinear systems. In *International Symposium on Aerospace/Defense Sensing, Simulation and Controls*, pages 182–193, Orlando, Florida, 1997.

- [Jul97] S. J. Julier. *Process Models for the Navigation of High Speed Land Vehicles*. PhD thesis, University of Oxford, Departement of Engineering Science, 1997.
- [Jul00] S. Julier. The scaled unscented transformation. *Automatica*, 2000.

K

- [Kal60] R. E. Kalman. A new approach to linear filtering and prediction system. *Transactions of the ASME-Journal of Basic Engineering*, 82(D) :35–45, 1960.
- [Kap96] E. D. Kaplan. *Understanding GPS. Principle and Applications*. Artech House, 1996.
- [KE95] J Kennedy and R Eberhart. Particle swarm optimization. *Proceedings of IEEE International Conference on Neural Networks IV*, pages 1942–1948, 1995.
- [Kel00] A. Kelly. Some useful results for closed-form propagation of error in vehicle odometry. Cmu-ri-tr-00-20, Robotics Institute, Carnegie Mellon University, 2000.
- [KFI08] R Kandepu, B Foss, and L Imsland. Applying the unscented kalman filter for nonlinear state estimation. *Journal of Process Control*, 18(7-8) :753–768, 2008.
- [KKE01] James Kennedy, James F Kennedy, and Russell C Eberhart. *Swarm intelligence*. Morgan Kaufmann, 2001.
- [KL02] Thiemo Krink and Morten Løvbjerg. The lifecycle model : combining particle swarm optimisation, genetic algorithms and hillclimbers. In *Parallel Problem Solving from Nature-PPSN VII*, pages 621–630. Springer, 2002.
- [KLW94] Augustine Kong, Jun S. Liu, and Wing Hung Wong. Sequential imputations and bayesian missing data problems. *Journal of the American Statistical Association*, 89 :278–288, 1994.
- [KMB⁺06] Mikaël Kais, Damien Millescamp, David Bétaille, Benoit Lusetti, and Antoine Chapelon. A multi-sensor acquisition architecture and real-time reference for sensor and fusion methods benchmarking. In *Intelligent Vehicles Symposium, 2006 IEEE*, pages 418–423. IEEE, 2006.

- [Kro04] R. A. Krohling. Gaussian swarm : a novel particle swarm optimization algorithm. In *IEEE Conference on Cybernetics and Intelligent Systems*, volume 1, December 2004.
- [KWSD04] N. Kaempchen, K. Weiss, M. Schaefer, and K. J. C. Dietmayer. Imm object tracking for high dynamic driving maneuvers. In *IEEE Intell. Vehicle Symp.*, Parma, Italy, June 2004.

L

- [Lan06] Jean Laneurit. *Perception multisensorielle pour la localisation d'un robot mobile en environnement extérieur, application aux véhicules routiers*. PhD thesis, Université Blaise Pascal-Clermont-Ferrand II, 2006.
- [Lap74] P.S. Laplace. Mémoire sur la probabilité des causes par les évènements. pages 6 :621–656, 1774.
- [Lat90] J. C. Latombe. *Robot Motion Planning*. Kluwer Academic Publishers, 1990.
- [LBCT03] J. Laneurit, C. Blanc, R. Chapuis, and L. Trassoudaine. Multi-sensorial data fusion for global vehicle and obstacles absolute positioning. In *IEEE Intelligent Vehicles Symposium*, pages 138–143, 2003.
- [LBDS04] Tine Lefebvre, Herman Bruyninckx, and Joris De Schutter. Kalman filters for non-linear systems : A comparison of performance. *International Journal of Control*, 77(7) :639–653, 2004.
- [LDW91] J. Leonard and H. Durrant-Whyte. Mobile robot localization by tracking geometric beacons. *IEEE Transaction on Robotics and Automation*, 7(3) :376–382, 1991.
- [Lec05] Bruno Lecoutre. Et si vous étiez un bayésien qui s'ignore. *Revue Modulad*, 32 :92–105, 2005.
- [Lew86] F. L. Lewis. *Optimal Estimation : with an introduction to stochastic control theory*. John Wiley & Sons, New York, 1986.
- [Li04] Xiaodong Li. Adaptively choosing neighbourhood bests using species in a particle swarm optimizer for multimodal function optimization. In *Genetic and Evolutionary Computation–GECCO 2004*, pages 105–116. Springer, 2004.

- [LJ03] X. R. Li and V. P. Jilkov. Survey of maneuvering target tracking. part 1 : Dynamic models. *IEEE Transactions on Aerospace and Electronic Systems*, 39(4) :1333–1364, 2003.
- [LJ05] X. R. Li and V. P. Jilkov. Survey of maneuvering target tracking. part 5 : Multiple model methods. *IEEE Transactions on Aerospace and Electronic Systems*, 41(4), 2005.
- [LK02] Morten Lovbjerg and Thiemo Krink. Extending particle swarm optimisers with self-organized criticality. In *Computational Intelligence, Proceedings of the World on Congress on*, volume 2, pages 1588–1593. IEEE, 2002.
- [LLZ⁺13] Xiaolei Liang, Wenfeng Li, Yu Zhang, Ye Zhong, and MengChu Zhou. Recent advances in particle swarm optimization via population structuring and individual behavior control. In *Networking, Sensing and Control (ICNSC), 2013 10th IEEE International Conference on*, pages 503–508, 2013.
- [LMBBG⁺08] Olivier Le Marchand, Philippe Bonnifait, Javier Bañez-Guzmán, François Peyret, David Betaille, et al. Performance evaluation of fault detection algorithms as applied to automotive localisation. In *European Navigation Conference-GNSS 2008*, 2008.
- [LV00] S. Lenser and M. Veloso. Sensor resetting localization for poorly modeled mobile robots. In *Int. Conf. on Robotics and Automation (ICRA)*, 2000.
- [LZ01] X. R. Li and Z. Zhao. Practical measures for performance evaluation of estimators and filters. In *Workshop on Estimation, Tracking, and Fusion - A Tribute to Yaakov Bar-Shalom*, pages 467–480, Monterey, CA, USA, 2001.

M

- [MABSD98] E. Mazor, A. Averbuch, Y. Bar-Shalom, and J. Dayan. Interacting multiple model methods in target tracking : a survey. *IEEE Transactions on Aerospace and Electronic Systems*, 34(1) :103–123, Jan. 1998.
- [Mag65] D. T. Magill. Optimal adaptive estimation of sampled stochastic processes. *IEEE Transactions on Automatic Control*, AC-10(4) :434–439, October 1965.

- [Mah07] Vemula Mahesh. Performance comparison of gaussian-based filters using information measures. *IEEE Signal Processing Letters*, 14 :1020–1023, 2007.
- [Mar99] Catherine Marselli. *Data Processing of a Navigation Microsystem*. PhD thesis, 1999.
- [May82] P. S. Maybeck. *Stochastic Models, Estimation and Control*. Academic Press, New York, 1982.
- [MdO07] Marco A. Montes de Oca. Particle swarm optimization-introduction. <http://iridia.ulb.ac.be/~mmontes/slidesCIL/slides.pdf>, May 7 2007.
- [Men04] Rui Mendes. *Population topologies and their influence in particle swarm performance*. PhD thesis, Universidade do Minho, 2004.
- [MGLG05] B. Mourllion, D. Gruyer, A. Lambert, and S. Glaser. Kalman filters comparison for vehicle localization data alignment. In *IEEE/RSJ International Conference on Advanced Robotics*, pages 178 – 185, July 2005.
- [MKD08] Vladimiro Miranda, Hrvoje Keko, and Álvaro Jaramillo Duque. Stochastic star communication topology in evolutionary particle swarms (epso). *International Journal of Computational Intelligence Research*, 4(2), 2008.
- [Mou06] B. Mourllion. *Extension d'un système de perception embarqué par communication. Application à la diminution du risque routier*. PhD thesis, Université Paris Sud (Orsay, Paris XI), 2006.
- [MS05] Christopher K Monson and Kevin D Seppi. Exposing origin-seeking bias in pso. In *Proceedings of the 2005 conference on Genetic and evolutionary computation*, pages 241–248. ACM, 2005.
- [MSS06] Michael Meissner, Michael Schmuker, and Gisbert Schneider. Optimized particle swarm optimization (opso) and its application to artificial neural network training. *BMC bioinformatics*, 7(1) :125, 2006.

N

- [NA10] Taher Niknam and Babak Amiri. An efficient hybrid approach based on pso, aco and k -means for cluster analysis. *Applied Soft Computing*, 10(1) :183–197, 2010.

- [NGG07] A. Ndjeng Ndjeng, S. Glaser, and D. Gruyer. A multiple model localization system for outdoor vehicles. In *IEEE/Intelligent Vehicles Symposium*, Istanbul, June 2007.
- [NGGL11] A. Ndjeng Ndjeng, D. Gruyer, S. Glaser, and A. Lambert. Low cost imu-odometer-gps ego localization with imm for unusual maneuvers. *Information Fusion*, 12(4) :264–274, 2011.
- [NGL⁺09] A.N. Ndjeng, D. Gruyer, A. Lambert, B. Mourllion, and S. Glaser. Experimental comparison of bayesian outdoor vehicle localization filters. In *ICRA09 Workshop on Safe navigation in open and dynamic environments Application to autonomous vehicles*, pages 113–118, Kobe, Japan, May 2009.
- [NN09] Alexandre Ndjeng Ndjeng. *Localisation robuste multi-capteurs et multi-modèles*. PhD thesis, Evry-Val d’Essonne, 2009.
- [NNB04] David Nistér, Oleg Naroditsky, and James Bergen. Visual odometry. In *Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on*, volume 1, pages I–652. IEEE, 2004.
- [NNLGG09] Alexandre Ndjeng Ndjeng, Alain Lambert, Dominique Gruyer, and Sebastien Glaser. Experimental comparison of kalman filters for vehicle localization. *IEEE Intelligent Vehicles Symposium*, pages 441–446, 2009.
- [NPR00] M. Nørgaard, N. K. Poulsen, and O. Ravn. Advances in derivative-free state estimation for nonlinear systems. Technical Report IMM-REP-1998-15, Technical University of Denmark, 2000.
- [NR95] K Naab and G Reichart. Driver assistance systems for lateral and longitudinal vehicle guidance-heading control and active cruise support. *JSAE Review*, 16(2), 1995.

O

- [Ols00] Clark F. Olson. Probabilistic self-localization for mobile robot. *IEEE Transaction on Robotics and Automation*, 16(1) :55–66, February 2000.

P

- [PC10] M.E.H. Pedersen and A.J. Chipperfield. Simplifying particle swarm optimization. *Applied Soft Computing*, 10(2) :618 – 628, 2010.
- [PdST09] Raquel Ramos Pinho and João Manuel Ribeiro da Silva Tavares. Comparison between kalman and unscented kalman filters in tracking applications of computational vision. In *VipIMAGE 2009-II ECCOMAS Thematic Conference on Computational Vision and Medical Image Processing*, 2009.
- [Ped10] Magnus Erik Hvass Pedersen. *Tuning & simplifying heuristical optimization*. PhD thesis, University of Southampton, 2010.
- [Pha01] Dinh Tuan Pham. Stochastic methods for sequential data assimilation in strongly nonlinear systems. *Monthly weather review*, 129(5) :1194–1207, 2001.
- [PZ04] P.A.Boysen and H. Zunker. Low cost sensor hybridisation and accuracy estimation for road applications. In *ESA Conf. Navitec*, Noordwijk, The Netherlands, Dec. 2004.

Q

- [QON06] Mohammed A Quddus, Washington Y Ochieng, and Robert B Noland. Integrity of map-matching algorithms. *Transportation Research Part C : Emerging Technologies*, 14(4) :283–302, 2006.

R

- [RCVT01] Benoit Roturier, Eric Chatre, and J Ventura-Traveset. The sbas integrity concept standardised by icao-application to egnos. *NAVIGATION-PARIS-*, 49 :65–77, 2001.
- [RLZ06] X. Rong Li and Zhanlue Zhao. Evaluation of estimation algorithms part i : incomprehensive measures of performance. *Aerospace and Electronic Systems, IEEE Transactions on*, 42(4) :1340–1358, October 2006.
- [RSC06] M. Reyes-Sierra and C. A. C. Coello. Multi-objective particle swarm optimizers : A survey of the state-of-the-art. *International Journal of Computational Intelligence Research*, 2(3), 2006.

S

- [SAC02] N. Gordon S. Arulampalam, S. Maskell and T. Clapp. A tutorial on particle filters for online non-linear/non-gaussian bayesian tracking. *IEEE Transactions on Signal Processing*, 50(2) :174–188, February 2002.
- [SC86] R. C. Smith and P. Cheeseman. On the representation and estimation of spatial uncertainty. *International Journal of Robotic Research*, 5(4) :56–67, 1986.
- [SC03] Brian G Saulson and Kuo-Chu Chang. Comparison of nonlinear estimation for ballistic missile tracking. *Proceedings of SPIE*, 43(6) :13–24, 2003.
- [SE98a] Yuhui Shi and Russell Eberhart. A modified particle swarm optimizer. In *In Proceedings of the IEEE International Conference on Evolutionary Computation*, pages 69–73, Piscataway, NJ, USA, 1998. IEEE Press.
- [SE98b] Yuhui Shi and Russell C Eberhart. Parameter selection in particle swarm optimization. In *Evolutionary Programming VII*, pages 591–600. Springer, 1998.
- [Sei06] Emmanuel Seignez. *Etude et comparaison expérimentale de méthodes de localisation multicapteurs*. 2006.
- [SGFR94] Bernd Simeon, F Grupp, C Führer, and P Rentrop. A nonlinear truck model and its treatment as a multibody system. *Journal of Computational and Applied Mathematics*, 50(1) :523–532, 1994.
- [SHI99] *Empirical study of particle swarm optimization*, volume 3, 1999.
- [SHL+05] Ponnuthurai N Suganthan, Nikolaus Hansen, Jing J Liang, Kalyanmoy Deb, Y-Po Chen, Anne Auger, and S Tiwari. Problem definitions and evaluation criteria for the cec 2005 special session on real-parameter optimization. *KanGAL Report*, 2005005, 2005.
- [SLM05] E. Seignez, A Lambert, and T. Maurin. Autonomous parking carrier for intelligent vehicle. In *IEEE International Conference on Intelligent Vehicle*, pages 411–416, 2005.
- [Spe10] Green D. T. & Spears D. F. Spears, W. M. Biases in particle swarm optimization. *International Journal of Swarm Intelligence Research*, 1(2) :34–57, 2010.

- [Suk00] Salah Sukkarieh. *Low cost, high integrity, aided inertial navigation systems for autonomous land vehicles*. PhD thesis, The University of Sydney, 2000.

T

- [TFBD00] S. Thrun, D. Fox, W. Burgard, and F. Dellaert. Robust monte carlo localization for mobile robots. *Artificial Intelligence*, 1-2 :99–141, 2000.
- [TFX06] Guofeng Tong, Zheng Fang, and Xinhe Xu. A particle swarm optimized particle filter for nonlinear system state estimation. In *IEEE Congress on Evolutionary Computation, CEC 2006.*, pages 438–442. IEEE, 2006.
- [TMZIUMGS06] R. Toledo-Moreo, M.A. Zamora-Izquierdo, B. Ubeda-Miarro, and A.F. Gomez-Skarmeta. Imm-ekf based road vehicle navigation with low cost gps/ins. In *2006 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems.*, pages 433 – 438, Sept. 2006.
- [TMZIUMGS07] R. Toledo-Moreo, M.A. Zamora-Izquierdo, B. Ubeda-Miarro, and A.F. Gomez-Skarmeta. High-integrity imm-ekf-based road vehicle navigation with low-cost gps/sbas/ins. *IEEE Transactions on Intelligent Transportation Systems*, 8(3) :491 – 511, Sept. 2007.
- [Tre03] Ioan Cristian Trelea. The particle swarm optimization algorithm : convergence analysis and parameter selection. *Information processing letters*, 85(6) :317–325, 2003.

V

- [vdMW01] Rudolph van der Merwe and Eric A. Wan. Efficient derivative-free kalman filters for online learning. In ISBN 2-930307-01-3 D-Facto public., editor, *European Symposium on Artificial Neural Networks (ESANN)*, pages 205–210, Bruges (Belgium), 25-27 April 2001.
- [Ven03] Gentiane Venture. *Identification des paramètres dynamiques d'une voiture*. PhD thesis, Ecole centrale de nantes-ECN, 2003.
- [VGKB04] Gentiane Venture, Maxime Gautier, Wisama Khalil, and Philippe Bodson. Parametric identification of the car dynamics. In *System Identification (SYSID'03) : A Proceedings Volume from the*

13th IFAC Symposium on System Identification, Rotterdam, the Netherlands, 27-29 August 2003, page 285. Elsevier, 2004.

W

- [WdM01] Eric A. Wan and Rudolph Van der Merwer. *Kalman Filtering and Neural Networks*, chapter Chapter 7 : The Unscented Particle Filter. Wiley Publishing, 2001.
- [WKG07] Daniel N Wilke, Schalk Kok, and Albert A Groenwold. Comparison of linear and classical velocity update rules in particle swarm optimization : Notes on scale and frame invariance. *International journal for numerical methods in engineering*, 70(8) :985–1008, 2007.
- [WV00] E. A. Wan and R. Van Der Merwe. The unscented kalman filter for nonlinear estimation. In *Adaptive Systems for Signal Processing, Communication and Control Symposium*, pages 153–158, Lake Louise, AB, Canada, 2000.

X

- [XH04] Russ Eberhart. Xiaohui Hu, Yuhui Shi. Recent advances in particle swarm. *Evolutionary Computation, 2004. CEC2004. Congress on*, 1, June 2004.
- [Xin10] Zhao Xinchao. A perturbed particle swarm algorithm for numerical optimization. *Applied Soft Computing*, 10(1) :119–124, 2010.

Y

- [YGLZ11] Peng-Yeng Yin, Fred Glover, Manuel Laguna, and Jia-Xian Zhu. A complementary cyber swarm algorithm. *International Journal of Swarm Intelligence Research (IJSIR)*, 2(2) :22–41, 2011.

Z

- [ZIBPJ08] Miguel A Zamora-Izquierdo, DF Betaille, François Peyret, and Cyril Joly. Comparative study of extended kalman filter, linearised kalman filter and particle filter applied to low-cost gps-based hybrid positioning system for land vehicles. *International Journal of Intelligent Information and Database Systems*, 2(2) :149–166, 2008.

- [ZPP11a] Jialong Zhang, Tien-Szu Pan, and Jeng-Shyang Pan. A parallel hybrid evolutionary particle filter for nonlinear state estimation. In *Robot, Vision and Signal Processing (RVSP), 2011 First International Conference on*, pages 308–312, 2011.
- [ZPP11b] Jialong Zhang, Tien-Szu Pan, and Jeng-Shyang Pan. A parallel hybrid evolutionary particle filter for nonlinear state estimation. In *Proceedings of the 2011 First International Conference on Robot, Vision and Signal Processing, RVSP '11*, pages 308–312, Washington, DC, USA, 2011. IEEE Computer Society.
- [ZZLC09] Zhi-Hui Zhan, Jun Zhang, Yun Li, and HS-H Chung. Adaptive particle swarm optimization. *Systems, Man, and Cybernetics, Part B : Cybernetics, IEEE Transactions on*, 39(6) :1362–1381, 2009.