



HAL
open science

Radar "Around-the-Corner": détection et localisation de cibles masquées en milieu urbain

Khac Phuc Hung Thai

► To cite this version:

Khac Phuc Hung Thai. Radar "Around-the-Corner": détection et localisation de cibles masquées en milieu urbain. Traitement du signal et de l'image [eess.SP]. Université Européenne de Bretagne, 2018. Français. NNT: . tel-02194856

HAL Id: tel-02194856

<https://hal.science/tel-02194856v1>

Submitted on 26 Jul 2019

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.

N° d'ordre : 2011telb0000

Sous le sceau de l'Université européenne de Bretagne

Télécom Bretagne

En habilitation conjointe avec l'Université de Bretagne Occidentale

Financée par ONERA

Ecole Doctorale – MathSTIC

Radar « Around the Corner » : détection et localisation de cibles masquées en milieu urbain

Thèse de Doctorat

Mention : Signal, Image, Vision

Présentée par **Khac Phuc Hung Thai**

Département : Electronique

Laboratoire : Lab STICC

Directeur de thèse : Thierry Chonavel

Soutenue le 14 décembre 2018

Jury :

M. Philippe Forster - Professeur à l'IUT de Ville d'Avray (Rapporteur)
Mme Stéphanie Bidon - Professeur à l'ISAE-SUPAERO (Rapporteuse)
M. Thierry Chonavel - Professeur à l'IMT Atlantique (Directeur de thèse)
Mme Atika Rivenq-Menhaj - Professeur à l'Université de Valenciennes (Présidente du jury)
M. François Septier - Professeur à l'Université Bretagne Sud (Examinateur)
M. Olivier Rabaste - Ingénieur de recherche à l'ONERA (Encadrant)
M. Jonathan Bosse - Ingénieur de recherche à l'ONERA (Encadrant)
M. Philippe Pouliguen - Responsable domaine scientifique DGA/MRIS (Invité)

Résumé

Les applications des techniques radar au milieu urbain constituent un domaine émergent. Une des difficultés principale est liée à la complexité du milieu de propagation induit par les bâtiments présents dans la scène. En effet, contrairement aux applications radar classiques où la cible est en ligne de vue du radar, la présence de ces bâtiments génère d'une part des zones d'ombre à l'intérieur desquelles une cible n'est pas en visibilité directe, et d'autre part de nombreux multi-trajets produits par les possibles réflexions et diffractions sur les surfaces environnantes. Ces multi-trajets sont souvent vus comme une gêne, limitant les capacités de détection en radar. Or ils peuvent aussi être exploités à l'avantage du radar afin de détecter et localiser des cibles situées dans les zones d'ombre (cible en NLOS).

L'objectif de ce travail de thèse est donc la mise en place de méthodes de traitement du signal permettant la détection et la localisation d'une cible en NLOS en milieu urbain et l'application de ces techniques pour détecter et localiser une cible en NLOS à partir de signaux réalistes voire réels.

Pour cela, nous avons proposé dans un premier temps deux solutions pour la détection et la localisation de la cible en exploitant les multi-trajets : l'algorithme FMU qui est basé sur une projection du signal reçu sur le sous-espace défini par les retards des multi-trajets et l'algorithme SLC qui est basé sur une intégration non cohérente de l'énergie des multi-trajets. Nous avons également affiné d'une part notre solution de détection en proposant une méthode de sélection du nombre de trajets fondée sur l'optimisation de la probabilité de détection, et d'autre part notre solution de localisation en proposant d'utiliser des critères de pénalisation permettant de limiter dans une certaine mesure le problème d'ambiguïté inhérent à la problématique « around-the-corner ». Dans un deuxième temps, nous avons développé deux filtres particuliers pour pister une cible en milieu urbain en présence de multi-trajets. Ces algorithmes ont été appliqués aux données réelles issues d'une expérimentation et ont montré des résultats prometteurs : même avec une connaissance approximative de la géométrie de la scène, il a été possible de détecter, localiser et suivre une cible en exploitant uniquement l'information fournie par les retards des multi-trajets.

Mots clés : détection, filtre particulière, localisation, milieu urbain, multi-trajets, NLOS, pistage, radar.

**Around the Corner Radar :
detection and localization of an
NLOS target in urban environment**

Abstract

The applications of radar techniques to the urban environment constitute an emerging subject. One of the main difficulties is related to the complexity of the propagation environment induced by the buildings present in the scene. Indeed, unlike conventional radar applications where the target is in line of sight of the radar, the presence of these buildings generates on the one hand shadow areas within which a target is not in line of sight, and on the other hand, many multipaths produced by reflections and diffractions on the surrounding surfaces. Classically, these multipaths are often seen as an inconvenience, limiting radar detection capabilities. However these multipaths can also be exploited to the advantage of the radar to detect and locate targets located in the shadows areas (target in NLOS).

The objective of this thesis work is therefore to develop signal processing methods allowing the detection and localization of a target located in shadow areas in urban environment and to apply these techniques for detecting and locating a target in NLOS from realistic or even real signals.

For this, we first proposed two solutions for detection and localization of a target by exploiting multipath information: the FMU algorithm which is based on a projection of the received signal on the subspace defined by the delays of the multipaths and the SLC algorithm that is based on a non-coherent integration of multipath energy. We have also improved on one hand our detection solution by proposing a method for selecting the number of paths based on the optimization of the probability of detection, and on the other hand our localization solution by proposing to use some penalization enabling to mitigate the ambiguity problem inherent to the "around-the-corner" problem. In a second step, we developed two particle filters to track a target in urban environment in the presence of multipaths. These algorithms have been applied to real data and showed promising results: even with an approximate knowledge of the geometry of the scene, it has been possible to detect, locate and track a target by exploiting only the information on multipath delays.

Keywords: detection, localization, multipath, NLOS, particle filter, radar, tracking, urban environment.

Remerciements

Je tiens à remercier Monsieur Olivier Rabaste et Monsieur Jonathan Bosse, Ingénieurs de Recherche à l'ONERA, qui m'ont encadré tout au long de cette thèse et qui m'ont fait partager leurs brillantes intuitions. Qu'ils soient aussi remerciés pour leur gentillesse et leur disponibilité permanente.

Je voudrais remercier grandement mon directeur de thèse, Monsieur Thierry Chonavel, Professeur à l'IMT Atlantique, pour toute son aide. Je suis ravi d'avoir travaillé en sa compagnie car outre son appui scientifique, il a toujours été disponible pour me conseiller au cours de l'élaboration de cette thèse.

J'adresse tous mes remerciements à Madame Stéphanie Bidon, Professeur à l'ISAE-SUPAERO, ainsi qu'à Monsieur Philippe Forster, Professeur à l'IUT de Ville d'Avray, de l'honneur qu'ils m'ont fait en acceptant d'être rapporteurs de cette thèse.

J'exprime ma gratitude à Madame Atika Rivenq-Menhaj, Professeur à l'Université de Valenciennes et à Monsieur François Septier, Professeurs à l'Université Bretagne Sud, qui ont bien voulu être examinateurs.

Je remercie également Monsieur Philippe Pouliguen, Responsable domaine scientifique DGA/MRIS pour l'honneur qu'il m'a fait d'être dans mon jury de thèse.

Je tiens à remercier Monsieur Israel Hinostroza et Monsieur Thierry Letertre, Ingénieurs de Recherche à SONDRRA pour leurs collaborations et leurs aides pour les expérimentations à Centrale Supélec.

Enfin, je tiens à remercier tous les membres de DEMR/TSI, spécialement à Monsieur Dominique Poullin et à Monsieur Marc Flécheux, qui par leurs paroles, leurs écrits, leurs conseils et leurs critiques ont guidé mes réflexions et ont accepté de me rencontrer et de répondre à mes questions durant mes recherches.

Table des matières

Résumé	i
Abstract	v
Remerciements	vii
Table des matières	ix
Liste des algorithmes	xii
Introduction	1
1 Traitement du signal radar et problématique du radar en milieu urbain	7
1.1 Traitement du signal radar	7
1.1.1 Principe général du radar	7
1.1.2 Modèle de signal radar	9
1.1.3 Filtre adapté	11
1.1.4 Détection et localisation en radar classique	13
1.1.5 Fonction d'ambigüité	14
1.1.6 Formes d'onde	15
1.1.6.1 Signal chirp ou LFM	15
1.1.6.2 Codes de phase	17
1.1.6.3 Signal OFDM	18
1.1.7 Pistage en radar	19
1.1.7.1 Représentation dans l'espace d'état	20
1.1.7.2 Filtre de Bayes	21
1.1.7.3 Filtre de Kalman	21
1.1.7.4 Filtre particulaire	24

TABLE DES MATIÈRES

1.2	Radar en milieu urbain	28
1.2.1	Multi-trajets	28
1.2.2	Élimination des échos fixes	29
1.2.3	Réflexions préliminaires sur le choix de la forme d'ondes	30
1.2.4	Cibles en NLOS en aéroporté	32
1.2.5	Radar around-the-corner (RAC)	34
1.2.5.1	Mesures réelles	34
1.2.5.2	Détection de cibles mobiles	35
1.2.5.3	Localisation d'une cible mobile	35
1.2.5.4	Pistage d'une cible mobile	37
1.3	Conclusion	37
2	Algorithmes de détection et localisation en milieu urbain	39
2.1	Introduction	39
2.2	Modèle du signal en milieu urbain	40
2.3	Solutions de détection et localisation	43
2.3.1	Application du filtre adapté mono-trajet (FA)	43
2.3.2	Application de la méthode des empreintes digitales (ED)	43
2.3.3	Filtre adapté multi-trajets (FMU)	46
2.3.4	Square law combiner (SLC)	50
2.3.5	Comparaison du FMU et du SLC	51
2.3.5.1	Comparaison des performances de détection	51
2.3.5.2	Comparaison du temps de calcul et de la mémoire	51
2.4	Sélection du nombre de trajets pris en compte	52
2.4.1	Comparaison des performances de détection : N vs $N+1$ trajets	53
2.4.2	Algorithme de sélection du nombre de trajets	55
2.5	Simulations et résultats	57
2.5.1	Description des simulations	57
2.5.2	Sélection du nombre de trajets	58
2.5.3	Comparaison des performances de détection	58
2.5.4	Résultats de localisation sur signaux simulés	61
2.6	Gestion des ambiguïtés	64
2.6.1	Pénalisation avec critère BIC	65
2.6.2	Pénalisation avec critère AIC	67
2.6.3	Pénalisation avec informations d'empreintes digitales	67
2.6.4	Résultats : diminution des ambiguïtés	69
2.7	Conclusion	73
3	Localisation et pistage d'une cible en NLOS par filtres particuliers	75
3.1	Introduction	75

3.2	Modèle d'état et modèle de mesure	76
3.3	Filtre particulaire classique	77
3.4	Filtre particulaire GLRT	78
3.5	Filtre particulaire Swerling I	80
3.5.1	Approche 1 : σ_ρ paramètre constant	82
3.5.2	Approche 2 : σ_ρ variable	83
3.6	Bornes de Cramér-Rao en pistage	84
3.6.1	Borne de Cramér-Rao classique	85
3.6.2	Borne de Cramér-Rao a posteriori (BCRP)	85
3.6.3	Borne de Cramér-Rao a posteriori conditionnelle (BCRPC)	88
3.7	Simulation et résultats	90
3.7.1	Description de la simulation	90
3.7.2	Estimation de la position de la cible avec le filtre particulaire GLRT	91
3.7.3	Estimation de la position de la cible avec le filtre particulaire Swerling I	94
3.7.3.1	Approche 1 :	94
3.7.3.2	Approche 2 :	95
3.7.4	Performances des filtres particuliers	100
3.8	Conclusion	103
4	Expérimentation et application des algorithmes sur données réelles	107
4.1	Description de l'expérimentation	107
4.1.1	Description du radar	107
4.1.2	Description du scénario	108
4.2	Interprétation des mesures	110
4.3	Détection et localisation sur les données réelles	113
4.3.1	Données et pré-traitement	113
4.3.2	Test de détection-localisation	114
4.4	Pistage sur les données réelles	120
4.4.1	Filtre particulaire GLRT	120
4.4.2	Filtre particulaire Swerling I	127
4.5	Conclusion	128
	Conclusion et perspectives	131

TABLE DES MATIÈRES

Annexes	135
A Dérivation de P_{FA} et P_d pour les algorithmes FMU et SLC	137
B Démonstration de la proposition 1	139
Table des figures	143
Liste des tableaux	149
Bibliographie	153

Introduction

Cadre général et objectifs

Les applications des techniques radar au milieu urbain constituent un domaine émergent. Une des difficultés principale est liée à la complexité du milieu de propagation induit par les bâtiments présents dans la scène. En effet, contrairement aux applications radar classiques où la cible est en ligne de vue du radar, la présence de ces bâtiments génère d'une part des zones d'ombre à l'intérieur desquelles une cible n'est pas en visibilité directe, et d'autre part de nombreux multi-trajets produits par les possibles réflexions et diffractions sur les surfaces environnantes (figure 0.0.1). Ces multi-trajets sont souvent vus comme une gêne, limitant les capacités de détection en radar. Or ces multi-trajets peuvent aussi être exploités à l'avantage du radar afin de détecter et localiser des cibles situées dans les zones d'ombre (cf. figure 0.0.1), c'est-à-dire aux endroits qui ne sont pas situés en ligne de vue directe (NLOS pour Non-Line-Of-Sight en anglais). En effet, une position (x, y) correspond à un ensemble de trajets portant de multiples informations : distances parcourues (retards), amplitudes, Doppler, angles, etc. Une fois que certaines de ces informations sont identifiées, il devient possible de remonter à la position de la cible en les recoupant grâce à l'utilisation d'un modèle de propagation. C'est le principe du radar « around-the-corner ».

Pour l'application visée, à savoir un radar portable directement utilisable en milieu urbain, le radar doit être petit et bas coût. Cela nécessite l'emploi de méthodes de traitement peu gourmandes en temps de calcul (puissance de calcul supposée limitée), et donc en particulier l'utilisation d'un modèle de propagation relativement simple : un modèle de tracé de rayons est considéré ici.

Malheureusement, toutes les informations liées à ces multi-trajets ne sont pas toujours disponibles ou exploitables. Par exemple, l'information d'amplitudes des trajets est très difficilement exploitable à cause de la connaissance imparfaite de la scène. En effet, l'exploitation des amplitudes nécessite un modèle a priori porté sur les amplitudes des multi-trajets. Or, l'absence de la connais-

sance parfaite des matériaux des surfaces de réflexions et de leurs réflectivités, ainsi que la bonne connaissance de la SER (Surface Équivalente Radar) de la cible pour tous les angles de présentation, ou bien encore les détails de la scène, ne permet pas de modéliser les amplitudes de façon réaliste. Donc une contrainte raisonnable pour traiter de la localisation de la cible en milieu urbain est de ne pas exploiter d'a priori sur les amplitudes des multi-trajets. Par un souci de simplicité qui se justifie par le peu d'études préalables à ce problème, nous ne considérons dans le cadre de cette thèse que les informations de distance (retard) des multi-trajets. D'autre part, l'exclusion du Doppler et de l'angle correspond effectivement à une contrainte imposée par le matériel expérimental à notre disposition. Également par souci de simplicité, ce travail fera l'hypothèse d'une seule cible présente dans la scène.

L'absence de la totalité des informations disponibles peut rendre le problème de localisation plus difficile à résoudre. Par exemple, comme l'amplitude des trajets est supposée inconnue et doit être estimée, deux positions partageant des retards communs et dont les retards distincts sont d'amplitudes faibles vont être difficiles à séparer, même si elles sont éloignées géométriquement. On parlera alors d'un problème d'ambiguïté. Il est clair que ce problème sera d'autant plus présent que la quantité d'informations différentes à disposition (distance, Doppler, angle) sera faible.




FIGURE 0.0.1 – La présence des zones d'ombre et des multi-trajets en milieu urbain.

L'objectif de ce travail de thèse est donc la mise en place de méthodes de traitement du signal permettant la détection et la localisation d'une cible située dans des zones d'ombre (cible en NLOS) en milieu urbain et l'application de ces techniques pour détecter et localiser une cible en NLOS à partir de signaux réalistes voire réels.

Pour cela, dans un premier temps, nous nous restreindrons au problème de la détection et de la localisation d'une seule cible en NLOS avec un unique radar portable présent dans la scène urbaine. L'information angulaire et Doppler des trajets n'est pas supposée connue. Contrairement aux études [Setlur 12] [O'connor 15] où les auteurs utilisent les mesures du temps d'arrivée (TOA), nous exploitons des signaux bruts. Notons que l'exploitation des signaux bruts et non des mesures TOA est optimale du point de vue de l'estimation. Traiter les signaux bruts permet également d'éviter le problème d'association potentiellement combinatoire [Weiss 11]. Pour la détection, nous visons à améliorer la performance de détection en utilisant simultanément l'information des multi-trajets. De plus, pour la localisation nous ne supposons pas que le nombre de multi-trajets est constant comme [Zetik 15] ou [Setlur 12] : cela dépend de la géométrie et de la configuration de la scène ; en particulier, il est potentiellement différent pour deux positions cibles différentes. Une connaissance approximative de la géométrie de la scène est supposée disponible, qui pourrait par exemple être extraite de cartes routières en libre accès. Un modèle de propagation simple basé sur le tracé de rayons sera utilisé pour exploiter la géométrie de la scène. En tant que telle, la solution de localisation que nous proposerons peut être appliquée à n'importe quelle configuration géométrique.

Dans un second temps, nous considérons le problème de pistage tout en utilisant les hypothèses présentées ci-dessus. Dans notre contexte, les filtres de type Kalman ne peuvent pas être utilisés car l'équation de mesure est non linéaire. En particulier, nous verrons que l'équation de mesure dépend de l'état cible lui-même d'une manière très complexe car le nombre de trajets dépend de la position de la cible. Nous proposons donc d'utiliser des filtres particuliers pour traiter la non-linéarité du modèle de mesure et gérer le modèle de propagation multi-trajets.

Contributions

Les contributions de la thèse s'organisent autour de deux axes d'études principaux :

- Premièrement, pour résoudre le problème de détection et localisation, nous avons développé deux solutions pour la détection et la localisation de la cible en exploitant les multi-trajets. Contrairement au filtre adapté classique qui n'exploite qu'un seul trajet à la fois, les algorithmes proposés exploitent les trajets simultanément et fournissent généralement de meilleures performances dans un scénario urbain typique. En particulier, nous montrons que l'exploitation des trajets multiples peut améliorer les performances de détection tant que le SNR des trajets supplémentaires est suffisant. Nous avons également développé un algorithme spécifique pour sélectionner le nombre de multi-trajets,

ce qui nous permet d'améliorer les performances de détection en optimisant la probabilité de détection. Pour le problème de localisation, les résultats obtenus par simulation montrent que les localisations cibles peuvent être estimées avec les deux algorithmes même en utilisant un modèle de propagation simple et une connaissance approximative de la géométrie de la scène. Cependant, il apparaît également que le problème de localisation adressé par l'application radar "around-the-corner" conduit à de fortes ambiguïtés spatiales inhérentes à la géométrie de la scène. Nous avons donc proposé trois corrections du test initialement proposé pour diminuer ces ambiguïtés.

- Deuxièmement, nous avons développé des algorithmes de pistage qui prennent en compte la dynamique de la cible, pour lever les ambiguïtés de localisation. Ces algorithmes améliorent l'estimation de la position de la cible par rapport aux algorithmes de localisation proposés précédemment. Un des problèmes à résoudre pour mettre en œuvre ce type de filtre est la prise en compte de l'évolution des amplitudes des multi-trajets inconnues et fortement dépendantes du contexte (type de cible, angle de présentation pour le multi-trajet considéré, type de matériau des surfaces de réflexions, nombre de rebonds, etc.). Les deux solutions proposées correspondent à deux stratégies différentes pour résoudre ce problème : le filtre particulaire GLRT fondé sur l'estimation des amplitudes au sens de Maximum de Vraisemblance et le filtre particulaire Swerling I fondé sur la marginalisation de la vraisemblance des données par rapport aux amplitudes. Ensuite, nous avons calculé les bornes de Cramér-Rao a posteriori conditionnelle et non conditionnelle dans notre cas particulier pour évaluer les performances des filtres particuliers proposés.

- Enfin, nous avons mis en place une expérimentation afin de tester les algorithmes développés sur des signaux réels issus d'un environnement plus réaliste. Les algorithmes de détection et localisation proposés ont été appliqués aux données réelles et montrent des résultats prometteurs. Même avec une connaissance approximative de la géométrie de la scène (portes, fenêtres et autres éléments ne sont pas modélisés), il a été possible de détecter, localiser et suivre une cible en exploitant seulement l'information sur les retards des multi-trajets.

Organisation de la thèse

Le premier chapitre propose un état de l'art du problème. Dans un premier temps, les principes de bases du traitement du signal radar, comme le filtre adapté pour la détection et la localisation des cibles ou les outils classiques pour le problème de pistage, sont présentés. Dans un second temps, nous présentons la problématique et l'état de l'art du radar en milieu urbain.

Le deuxième chapitre traite le problème de détection et localisation d'une

cible en milieu urbain. Dans ce chapitre, nous proposons tout d'abord deux algorithmes de détection et localisation, puis les comparons en termes de performance de détection, de temps de calcul et de mémoire requise. Nous proposons également un algorithme pour la sélection du nombre de trajets pris en compte par les deux algorithmes de détection et localisation proposés. Pour finir, nous présentons le problème d'ambiguïté rencontré en milieu urbain et proposons des solutions basées sur la pénalisation selon la complexité du modèle qui permettent d'alléger les ambiguïtés.

Le troisième chapitre propose une autre solution pour diminuer les ambiguïtés rencontrés : l'exploitation de la dynamique de la cible au cours du temps par filtrage particulaire. Dans ce chapitre, nous proposons le filtre particulaire GLRT et le filtre particulaire Swerling I puis comparons leurs performances avec les performances des méthodes de localisation proposées au chapitre 2. Nous calculons également deux bornes de Cramér-Rao pour le pistage et évaluons les performances des filtres proposées par rapport aux bornes.

Le quatrième chapitre décrit les expérimentations effectuées et présente les résultats de l'application des algorithmes proposés au chapitres 3 et 4 aux données réelles.

Liste des publications

Articles de conférence :

- K. Thai, O. Rabaste, J. Bosse, D. Poullin, I. Hinostroza, T. Letertre, and T. Chonavel, "Around-the-corner radar : Detection and localization of a target in nonline of sight" in Radar Conference (RadarConf), 2017 IEEE (pp. 0842-0847).
- K. Thai, O. Rabaste, J. Bosse, D. Poullin, I. Hinostroza, T. Letertre, and T. Chonavel, « Radar around-the-corner : Détection et localisation d'une cible en non ligne de vue », GRETSI 2017
- K. Thai, O. Rabaste, J. Bosse, and T. Chonavel, « GLRT Particle filter for tracking NLOS target in around-the-corner radar », 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2018. p. 3216-3220.

Articles de revue internationale :

- K. Thai, O. Rabaste, J. Bosse, D. Poullin, I. Hinostroza, T. Letertre, and T. Chonavel, « Detection-localization algorithms in the around-the-corner radar problem », IEEE Transactions on Aerospace and Electronic systems, 2018 (accepté).
- K. Thai, O. Rabaste, J. Bosse, and T. Chonavel, « Solutions to the ambiguity problem in around-the-corner radar », en préparation pour IEEE Transactions on Aerospace and Electronic systems.

Chapitre 1

Traitement du signal radar et problématique du radar en milieu urbain

Ce chapitre vise dans un premier temps à introduire les principales notions générales du traitement du signal radar classique concernant différents aspects : la détection, la localisation et le pistage. Dans un second temps, la problématique du radar en milieu urbain sera introduite, puis l'état de l'art du problème sera étudié.

1.1 Traitement du signal radar

1.1.1 Principe général du radar

Radar est l'acronyme anglais de RAdio Detection And Ranging qui peut se traduire par « détection et télémétrie radio ». Un radar est un système électromagnétique qui permet de détecter et localiser des objets [Merrill 62]. Un radar dispose d'un émetteur et d'un récepteur d'ondes électromagnétiques. Il utilise des impulsions d'ondes électromagnétiques émises en direction de la cible. Une petite partie de l'énergie de l'onde transmise est réfléchiée par la cible dans la direction du radar. Cette onde renvoyée par la cible jusqu'au radar est appelée écho. Un radar utilise l'écho reçu afin de déterminer la présence ainsi que la direction et la distance de la cible. La mesure de la distance par un radar est possible du fait des propriétés de l'onde électromagnétique.

- Cette onde circule normalement dans l'espace en ligne droite et à vitesse constante (même si elle peut être soumise à des variations minimales dues aux conditions météorologiques et atmosphériques).

- L'onde électromagnétique se déplace dans l'air approximativement à la vitesse de la lumière.
- Les ondes électromagnétiques sont réfléchies lorsqu'elles « rencontrent » une surface conductrice. Si après l'émission d'un signal, on reçoit une copie retardée de ce signal, alors on a la preuve qu'un obstacle se trouve dans la direction de propagation.




FIGURE 1.1.1 – Principe du radar classique.

Le temps nécessaire à l'aller et au retour des impulsions τ peut être converti en distance R , sachant que la vitesse des ondes électromagnétiques c est connue, sous la forme :

$$R \approx \frac{c\tau}{2}. \quad (1.1)$$

De plus, en présence d'une cible mobile, il peut survenir une différence entre la fréquence du signal reçu f_R et le signal émis f_0 , phénomène connu sous le nom d'effet Doppler. L'effet Doppler peut être utilisé par un radar pour extraire différentes informations, par exemple :

- Mesurer la vitesse des cibles ;
- Filtrer des échos fixes pour détecter les cibles mobiles.

Il est démontré dans le paragraphe suivant que si la largeur de bande du signal est étroite par rapport à la fréquence porteuse f_0 et que la vitesse radiale de la cible v par rapport au radar est beaucoup plus petite que la vitesse de propagation c , ce décalage de fréquence ν peut être calculé par l'équation :

$$\nu = f_R - f_0 \approx \frac{2v}{\lambda}, \quad (1.2)$$

où λ est la longueur d'onde du signal émis. Par convention, la vitesse radiale v est négative lorsque la cible s'éloigne du radar, et positive lorsque la cible se rapproche du radar. La fréquence Doppler ν est donc positive lorsque la cible se rapproche du radar, et négative lorsqu'elle s'éloigne du radar.

Nous présentons dans le paragraphe suivant le signal radar utilisé dans le problème radar classique.

1.1.2 Modèle de signal radar

Un signal radar émis sur porteuse peut être décrit par l'équation suivante :

$$s(t) = Au(t) \exp(j2\pi f_0 t), \quad (1.3)$$

où f_0 est la fréquence porteuse, A est l'amplitude du signal s , $u(t)$ est le signal émis en bande de base, de largeur de bande B et d'énergie égale à 1. En réception, le signal reçu après avoir été réfléchi par la cible est une version atténuée et retardée d'un retard $\tau(t)$ du signal transmis $s(t)$. $\tau(t)$ est le temps d'aller-retour entre la cible et le radar. Le signal reçu est alors fourni par :

$$r(t) = \alpha Au(t - \tau(t)) \exp(j2\pi f_0(t - \tau(t))), \quad (1.4)$$

où α est un coefficient d'atténuation lié à l'atténuation de l'onde, que nous supposons inconnu. Notons que le signal reçu par le radar à un temps donné t est réfléchi par la cible à $t - \tau(t)/2$. Par conséquent, le retard aller-retour $\tau(t)$ doit vérifier la relation [Le Chevalier 02] :

$$c\tau(t) = 2R \left(t - \frac{\tau(t)}{2} \right), \quad (1.5)$$

où $R(\cdot)$ est la distance entre le radar et la cible au temps t qui peut s'écrire $R(t) = R_0 - vt$ pour une cible présentant un mouvement rectiligne uniforme de vitesse radiale v . Nous en déduisons :

$$\tau(t) = \frac{2R_0/c}{1 - v/c} - \frac{2tv/c}{1 - v/c}. \quad (1.6)$$

Nous avons donc :

$$u(t - \tau(t)) = u \left(t - \frac{2R_0/c}{1 - v/c} + \frac{2v/c}{1 - v/c} t \right) \quad (1.7)$$

$$= u \left(t \left(1 + \frac{2v/c}{1 - v/c} \right) - \frac{2R_0/c}{1 - v/c} \right). \quad (1.8)$$

L'enveloppe du signal reçu est caractérisée par deux termes : le retard

$$\tau = \frac{2R_0/c}{1 - v/c} \approx \frac{2R_0}{c}, \quad (1.9)$$

(car dans la plupart des cas en radar, $v \ll c$) et la modification d'échelle de temps, qui est multipliée par $1 + \frac{2v/c}{1 - v/c}$. Cette modification d'échelle de temps qui induit un phénomène de compression/dilatation du signal, est négligée la plupart du temps en radar puisque $1 + \frac{2v/c}{1 - v/c} \approx 1$ [Le Chevalier 02].

Le signal reçu est modulé par le terme :

$$m(t) = \exp(j2\pi f_0(t - \tau(t))) \quad (1.10)$$

$$= \exp\left(j2\pi f_0\left(1 + \frac{2v/c}{1 - v/c}\right)t\right) \exp\left(-j\frac{2\pi f R_0/c}{1 - v/c}\right), \quad (1.11)$$

où nous pouvons séparer un terme de déphasage constant

$$\phi = \frac{2\pi f R_0/c}{1 - v/c} \quad (1.12)$$

et un terme de décalage Doppler

$$\nu = f_0 \frac{2v/c}{1 - v/c}. \quad (1.13)$$

La fréquence porteuse dans le cas $v \ll c$ est donc décalée par

$$\nu \approx f_0 \frac{2v}{c} = \frac{2v}{\lambda}. \quad (1.14)$$

Le signal reçu par le radar est démodulé pour enlever la fréquence porteuse $\exp(j2\pi f_0 t)$ et nous obtenons alors le signal continu :

$$r(t) \approx \alpha A u(t - \tau) \exp(j2\pi \nu t). \quad (1.15)$$

Pour les traitements numériques en temps discret, le signal reçu est échantillonné à la fréquence f_s satisfaisant le théorème de Nyquist ($f_s \geq 2B$) :

$$r(t_n) = r(nT_s), \quad (1.16)$$

où $T_s = 1/f_s$ est la période d'échantillonnage et $n = 0, 1, \dots, N_s - 1$, où N_s est le nombre d'échantillons enregistrés. Nous pouvons mettre le signal reçu sous forme de vecteur :

$$\mathbf{r} = [r(t_0), r(t_1), \dots, r(t_{N_s-1})] \quad (1.17)$$

$$= \alpha A \mathbf{u}(\tau) \odot \mathbf{d}(\nu), \quad (1.18)$$

où $\tau \approx \frac{2R_0}{c}$, $\nu \approx \frac{2v}{\lambda}$,

$$\mathbf{u}(\tau) = [u(t_0 - \tau), u(t_1 - \tau), \dots, u(t_{N_s-1} - \tau)], \quad (1.19)$$

$$\mathbf{d}(\nu) = [\exp(j2\pi\nu t_0), \exp(j2\pi\nu t_1), \dots, \exp(j2\pi\nu t_{N_s-1})], \quad (1.20)$$

et \odot représente le produit d'Hadamard (terme à terme).

Le défi principal du radar est de détecter la présence de cibles par une étude du signal reçu. Dans le cas où la cible est présente, le radar cherche à estimer les principales informations comme le retard τ et le décalage Doppler ν permettant de remonter à l'information de distance et vitesse de la cible. Enfin, une étape de pistage s'ajoute pour estimer et améliorer la précision de ces informations de cibles au cours du temps. La chaîne classique de traitement radar est illustrée en figure 1.1.2.




FIGURE 1.1.2 – Chaîne classique de traitement radar

Nous présentons dans le paragraphe suivant le filtre adapté, un outil classiquement utilisé pour les deux problèmes de détection et d'estimation.

1.1.3 Filtre adapté

Dans les applications radar, nous utilisons le signal reçu connu pour détecter la présence d'une cible. En supposant que \mathbf{s} est un signal complexe connu déterministe, le problème de détection peut s'exprimer par le test d'hypothèses suivant :

$$\begin{cases} H_0 : \mathbf{r} = \mathbf{n}, & \text{bruit seul} \\ H_1 : \mathbf{r} = A\mathbf{s} + \mathbf{n}, & \text{cible+bruit} \end{cases}, \quad (1.21)$$

où nous supposons ici que \mathbf{n} est un bruit circulaire blanc gaussien complexe de matrice de covariance $\sigma^2\mathbf{I}$ et l'amplitude A est déterministe inconnue. L'objectif est de sélectionner l'hypothèse H_1 quand la cible est présente et sélectionner l'hypothèse H_0 quand la cible est absente. Il y a deux quantités principales dans la décision du test d'hypothèses précédent : la probabilité de fausse alarme P_{FA} et la probabilité de détection P_d . Une fausse alarme est l'erreur commise quand nous sélectionnons l'hypothèse H_1 tandis que l'hypothèse H_0 est vraie. P_{FA} est la probabilité liée à cette erreur. La probabilité de sélection de l'hypothèse H_1 quand cette hypothèse est vraie est appelée la probabilité de détection. De manière générale, nous voulons une probabilité de détection élevée. Toutefois, chercher à augmenter cette quantité mènera à augmenter la probabilité de

fausse alarme, ce que nous voulons limiter. Il y a donc un compromis à trouver entre ces deux quantités. Le critère de Neyman-Pearson a été développé pour maximiser la probabilité de détection P_d tout en assurant une P_{FA} donnée [Kay 13], [Le Chevalier 02]. Il consiste à comparer le rapport entre la vraisemblance du signal \mathbf{r} sous l'hypothèse H_1 et la vraisemblance du même signal sous l'hypothèse H_0 avec un seuil, ce qui est connu sous le nom du LRT (Likelihood Ratio Test). On choisit alors l'hypothèse H_1 si ce rapport est supérieur à un certain seuil λ :

$$L(\mathbf{r}) = \frac{p(\mathbf{r}|H_1)}{p(\mathbf{r}|H_0)} \underset{H_0}{\overset{H_1}{\geq}} \lambda, \quad (1.22)$$

où

$$p(\mathbf{r}|H_1) = \frac{1}{\pi^{N_S} \sigma^{2N_S}} \exp\left(-\frac{(\mathbf{r} - A\mathbf{s})^H (\mathbf{r} - A\mathbf{s})}{\sigma^2}\right), \quad (1.23)$$

$$p(\mathbf{r}|H_0) = \frac{1}{\pi^{N_S} \sigma^{2N_S}} \exp\left(-\frac{\mathbf{r}^H \mathbf{r}}{\sigma^2}\right). \quad (1.24)$$

En pratique, le paramètre A est inconnu et la vraisemblance $p(\mathbf{r}|H_1)$ ne peut pas être calculé directement. On recourt dans ce cas dans la littérature au GLRT (Generalized Likelihood Ratio Test) qui consiste à injecter dans le LRT l'estimation des paramètres inconnus au sens de Maximum de Vraisemblance :

$$L(\mathbf{r}) = \frac{\max_A p(\mathbf{r}|H_1)}{p(\mathbf{r}|H_0)} \underset{H_0}{\overset{H_1}{\geq}} \lambda. \quad (1.25)$$

En particulier, dans notre application, l'estimation au sens du Maximum de Vraisemblance du paramètre A inconnu qui maximise (1.23) est donnée par :

$$\hat{A} = (\mathbf{s}^H \mathbf{s})^{-1} \mathbf{s}^H \mathbf{r}, \quad (1.26)$$

Le test d'hypothèses devient alors :

$$L(\mathbf{r}) = \exp\left(\frac{\mathbf{r}^H \mathbf{s} (\mathbf{s}^H \mathbf{s})^{-1} \mathbf{s}^H \mathbf{r}}{\sigma^2}\right) \underset{H_0}{\overset{H_1}{\geq}} \lambda. \quad (1.27)$$

En prenant le logarithme des deux côtés de l'équation (1.22), nous avons :

$$\frac{|\mathbf{r}^H \mathbf{s}|^2}{\mathbf{s}^H \mathbf{s}} \underset{H_0}{\overset{H_1}{\geq}} \lambda'. \quad (1.28)$$

Le seuil λ' est choisi pour satisfaire la probabilité de fausse alarme P_{FA} donnée.

Ce test revient à comparer $\frac{|\mathbf{r}^H \mathbf{s}|^2}{\mathbf{s}^H \mathbf{s}}$ avec un seuil. Cette quantité est aussi connue sous le nom de filtre adapté. Il est démontré que le filtre adapté est un filtre linéaire optimal qui maximise le SNR pour un signal connu et en présence du bruit [Levanon 04]. Il consiste à calculer la corrélation entre le signal reçu et le signal émis \mathbf{s} .

1.1.4 Détection et localisation en radar classique

En radar classique, le signal réfléchi par la cible subit un temps de retard τ et un décalage de fréquence Doppler ν , ce qui implique que l'écho ne se corrèle pas avec le signal transmis, sauf si nous appliquons les mêmes décalages temporel et fréquentiel sur le signal référence. Ainsi, la corrélation est effectuée pour une batterie de filtres adaptés, chacun étant réglé sur un retard et un décalage Doppler différent. Cette corrélation pour différents paramètres temporels et fréquentiels vise deux objectifs distincts dans le radar : (1) fournir le gain d'intégration nécessaire pour permettre la détection de l'écho de la cible, et (2) estimer le retard et le décalage Doppler de la cible pour le problème de localisation de la cible. D'après ce qui a été dit précédemment, le test de détection est fourni pour une hypothèse donnée (τ, ν) par :

$$T(\tau, \nu) = \frac{|\mathbf{r}^H \mathbf{s}(\tau, \nu)|^2}{\mathbf{s}(\tau, \nu)^H \mathbf{s}(\tau, \nu)} \underset{H_0}{\overset{H_1}{\geq}} \lambda \quad (1.29)$$

avec

$$\mathbf{s}(\tau, \nu) = \mathbf{u}(\tau) \odot \mathbf{d}(\nu),$$

$$\mathbf{u}(\tau) = [u(t_0 - \tau), u(t_1 - \tau), \dots, u(t_{N_s-1} - \tau)],$$

$$\mathbf{d}(\nu) = [\exp(j2\pi\nu t_0), \exp(j2\pi\nu t_1), \dots, \exp(j2\pi\nu t_{N_s-1})]$$

où λ est un seuil défini en fonction de la probabilité de fausse alarme exigée. En l'absence de la connaissance de la position de la ou des cibles, on balaye tout l'espace d'observation (τ, ν) discrétisé sur une grille; une détection est déclarée pour toute case (τ, ν) validant le test (1.29) sous l'hypothèse H_1 .

Pour le problème de la localisation des cibles, l'estimateur du Maximum de Vraisemblance des paramètres (τ, ν) est donné par :

$$(\hat{\tau}, \hat{\nu}, \hat{A}) = \arg \max_{\tau, \nu, A} \ln(p(\mathbf{r}|\tau, \nu, A)) = \arg \max_{\tau, \nu, A} -\frac{1}{\sigma^2} \|\mathbf{r} - A\mathbf{s}(\tau, \nu)\|^2, \quad (1.30)$$

où A est remplacé par son estimateur au sens de Maximum de Vraisemblance \hat{A} donnée par l'équation (1.26), nous avons alors :

$$\arg \max_{\tau, \nu} \ln \left(p(\mathbf{r} | \tau, \nu, \hat{A}) \right) = \arg \max_{\tau, \nu} \mathbf{r}^H \mathbf{s}(\tau, \nu) \left(\mathbf{s}(\tau, \nu)^H \mathbf{s}(\tau, \nu) \right)^{-1} \mathbf{s}(\tau, \nu)^H \mathbf{r}. \quad (1.31)$$

Nous voyons que pour une même cible, le GLRT et l'estimateur du Maximum de Vraisemblance font intervenir la même quantité $T(\tau, \nu)$. Les paramètres (τ, ν) de la cible sont donc estimés par :

$$(\hat{\tau}, \hat{\nu}) = \underset{\tau, \nu}{\operatorname{argmax}} T(\tau, \nu). \quad (1.32)$$

Dans le problème multi-cibles, il est plus complexe de calculer l'estimateur au sens du Maximum de Vraisemblance car le nombre de cibles est inconnue. Classiquement, nous utilisons donc le critère mono-cible et effectuons une optimisation locale :

$$(\hat{\tau}, \hat{\nu}) = \underset{\tau, \nu \in \mathcal{C}_0}{\operatorname{argmax}} T(\tau, \nu), \quad (1.33)$$

où \mathcal{C}_0 représente l'espace local des paramètres au voisinage d'une détection donnée.

L'estimation de la distance et la vitesse de la cible ou des cibles au radar peut alors être déduite à partir de $\hat{\tau}$ et $\hat{\nu}$ par les équations (1.1) et (1.2). Intuitivement, afin d'obtenir une bonne estimation de ces paramètres, l'énergie de $T(\tau, \nu)$ doit être concentrée autour de $(\hat{\tau}, \hat{\nu})$. La validité de cette hypothèse est bien évidemment liée à la forme d'onde \mathbf{u} . Nous présentons un outil pour caractériser cette propriété, la fonction d'ambigüité dans le paragraphe 1.1.5 et différentes formes d'onde dans le paragraphe 1.1.6.

1.1.5 Fonction d'ambigüité

La fonction d'ambigüité représente la sortie du filtre adapté au signal émis quand le signal de la cible est reçu avec un retard τ et un décalage Doppler ν relatif aux valeurs nominales attendues par le filtre adapté [Levanon 04]. En injectant l'expression de \mathbf{r} de l'équation (1.18) sous l'hypothèse de présence de la cible dans l'équation (1.29), nous avons :

$$T(\tau, \nu) = \alpha A (\mathbf{u}(\tau_c) \odot \mathbf{d}(\nu_c))^H (\mathbf{u}(\tau) \odot \mathbf{d}(\nu)) + \mathbf{n}^H (\mathbf{u}(\tau) \odot \mathbf{d}(\nu)) \quad (1.34)$$

$$= \alpha A \mathbf{u}^H(\tau_c) (\mathbf{u}(\tau) \odot \mathbf{d}(\nu - \nu_c)) + \eta(\tau, \nu) \quad (1.35)$$

$$= \alpha A \chi(\tau - \tau_c, \nu - \nu_c) + \eta(\tau, \nu) \quad (1.36)$$

où $\eta(\tau, \nu)$ désigne le terme de bruit après corrélation. La fonction $\chi(\tau, \nu)$ s'appelle la fonction d'ambiguïté. La fonction d'ambiguïté de la forme d'ondes \mathbf{u} du signal émis dans le domaine discret est définie par :

$$\chi(\tau, \nu) = \mathbf{u}^H (\mathbf{u}(\tau) \odot \mathbf{d}(\nu)). \quad (1.37)$$

Un Doppler positif ν signifie que la cible va vers le radar. La valeur absolue de la fonction d'ambiguïté atteint son maximum pour le couple $(\tau, \nu) = (0, 0)$:

$$|\chi(0, 0)|^2 = \mathbf{u}^H \mathbf{u} = E_u, \quad (1.38)$$

où E_u est l'énergie de la forme d'onde émise.

La forme d'onde \mathbf{u} optimale est celle qui produirait une fonction d'ambiguïté de la forme :

$$|\chi(0, 0)|^2 = \begin{cases} E_u & \text{pour } (\tau, \nu) = (0, 0) \\ 0 & \text{ailleurs.} \end{cases} \quad (1.39)$$

En réalité, une telle forme d'onde n'existe pas. En effet, la largeur du lobe principal de la fonction d'ambiguïté selon l'axe temporel qui correspond à la résolution temporelle est de l'ordre de l'inverse de la largeur de bande du signal émis B . Selon l'axe fréquentiel, cette largeur, qui correspond à la résolution Doppler, est de l'ordre de l'inverse de la durée d'intégration T_r . Ces deux largeurs peuvent être réduites en augmentant la bande B et la durée T_r mais ne sont jamais égales à 0. Nous présentons les différentes formes d'onde courantes dans la suite et examinons leurs caractéristiques.

1.1.6 Formes d'onde

Dans ce paragraphe, nous présentons certaines formes d'onde courantes utilisées en radar (FMCW), ou en télécommunications (codes de phases, OFDM), candidates pour être utilisées dans notre application plus spécifique du radar « around the corner ». Puis, nous comparons certaines de leurs caractéristiques dans le paragraphe 1.2.3.

1.1.6.1 Signal chirp ou LFM

La modulation linéaire de fréquence (en anglais LFM ou Linear frequency modulation) est la première et la plus populaire des techniques de compression d'impulsion en radar. L'idée de base est de balayer la bande de fréquence linéairement pendant une durée d'impulsion T pour augmenter la largeur de bande




FIGURE 1.1.3 – Exemple de la fonction d’ambiguïté d’un signal à modulation linéaire de fréquence d largeur de bande de 100 MHz.

et donc améliorer la résolution en distance du radar. L’enveloppe complexe d’une impulsion LFM est fournie par :

$$u(t) = \frac{1}{\sqrt{T}} \text{rect}\left(\frac{t}{T}\right) \exp\left(j\pi \frac{B}{T} t^2\right), \quad (1.40)$$

où

$$\text{rect}\left(\frac{t}{T}\right) = \begin{cases} 1 & \text{si } -T/2 \leq t \leq T/2; \\ 0 & \text{sinon.} \end{cases} \quad (1.41)$$

La fréquence instantanée, obtenue par la différenciation de l’argument de l’exponentiel, et fournie par :

$$f(t) = \frac{1}{2\pi} \frac{d\left(\pi \frac{B}{T} t^2\right)}{dt} = \frac{B}{T} t, \quad (1.42)$$

est effectivement une fonction linéaire du temps t . Un exemple de forme d’onde LFM est montré en figure 1.1.4 : on observe bien l’augmentation de la fréquence au cours du temps par le resserrement de la sinusoïde.

La modulation FMCW (Frequency Modulation Continuous Wave) est un train continu d’impulsions LFM. Le signal $s(t)$ émis par le radar FMCW pendant la durée d’une impulsion T , pour $t \in [0, T)$ s’écrit sous la forme :

$$s(t) = u(t) \exp(j2\pi f_0 t), \quad (1.43)$$




FIGURE 1.1.4 – Forme d’onde LFM avec largeur de bande de 400 MHz.

où A , f_0 , B et T sont respectivement l’amplitude, la fréquence porteuse, la largeur de bande et la durée d’une impulsion LFM. Le signal continu émis est alors donné par :

$$s_{FM CW}(t) = \sum_{k \in \mathbb{Z}} s(t - kT). \quad (1.44)$$

1.1.6.2 Codes de phase

Les codes de phase représentent une autre classe alternative de signal intéressante, et sont utilisés aussi bien dans les applications radar que de télécommunications. De nombreuses familles de codes de phase existent alors dans la littérature. Nous en présentons deux particulières dans ce qui suit.

Séquences SBLM

Une séquence binaire de longueur maximale (SBLM) est une séquence binaire pseudo-aléatoire de longueur $P = 2^N - 1$ où N est un entier naturel. Chaque élément de la séquence peut prendre la valeur 1 ou -1. Son auto-corrélation circulaire est proche d’un Dirac, car elle vaut P pour le décalage zéro et ± 1 pour les autres décalages, comme nous pouvons voir en figure 1.1.5. Ce type d’auto-corrélation est très proche de celle d’un bruit blanc, d’où son nom pseudo-aléatoire. Il n’existe toutefois pas beaucoup de telles séquences.

Codes de Zadoff-Chu

Au contraire de la forme d’onde SBLM dont la longueur est limitée à $2^N - 1$, il existe des séquences de Zadoff-Chu de n’importe quelle longueur. L’auto-corrélation circulaire de ce type de code est une réponse impulsionnelle parfaite, c’est-à-dire qu’elle vaut 0 partout sauf au décalage 0.




FIGURE 1.1.5 – Module de l'auto-corrélation circulaire des séquences SBLM et Zadoff-Chu de longueur 63 ($N=6$).

La séquence de code proposée par Zadoff [Zadoff 63] est fournie par $s_m = \exp(j\phi_m)$, avec

$$\phi_M = \frac{2\pi}{M}(m-1) \left(r \frac{M-1-m}{2} - q \right), \quad (1.45)$$

où $1 \leq m \leq M$, $0 \leq q \leq M$ sont des entiers quelconques et r est un entier relativement premier à M . Un cas particulier de la séquence Zadoff a été proposé par [Chu 72], pour

$$\phi_M = \begin{cases} \frac{2\pi r' (m-1)^2}{M}, & M \text{ pair,} \\ \frac{2\pi r' (m-1)m}{M}, & M \text{ impair,} \end{cases} \quad (1.46)$$

où $1 \leq m \leq M$ et r' est un entier relativement premier à M . Cette séquence est alors appelé Zadoff-Chu.

1.1.6.3 Signal OFDM

En télécommunications, la modulation OFDM (Orthogonal Frequency-Division Multiplexing) est une technique de codage de l'information sur des sous-porteuses fréquentielles orthogonales entre elles. La création d'un symbole OFDM se fait très simplement par simple FFT des symboles temporels. Le signal transmis est donc une somme des différents signaux :

$$s(t) = \sum_{k=0}^{N_c-1} A_k \exp(j2\pi f_k t), \quad (1.47)$$

où N_c est le nombre de porteuses choisies, A_k est un nombre complexe choisi dans un ensemble de valeurs possibles (par exemple, en QPSK, A_k peut prendre

les valeurs $(1 \pm j)/\sqrt{2}$ et $(-1 \pm j)/\sqrt{2}$, et f_k est la fréquence de la porteuse k [Lagrange 12].

Nous examinons deux variantes de l'OFDM. La première variante que nous appellerons ici OFDM aléatoire, considère simplement les symboles A_k choisis de manière aléatoire parmi différents symboles de la constellation considérée (par exemple QPSK ou 16-QAM). Le problème de cette stratégie aléatoire est qu'elle ne permet pas de contrôler l'évolution de l'énergie émise au cours du temps. Cela conduit à un facteur de crête très important du signal temporel (voir paragraphe 1.2.3). Il existe plusieurs variantes de l'OFDM. Nous nous intéressons ici plus particulièrement à une variante pour laquelle des coefficients fréquentiels sont choisis selon une séquence complémentaire de Golay. Nous appellerons dans la suite cette variante OFDM Golay.

Soit $a = (a_0, a_1, \dots, a_{N-1})$ et $b = (b_0, b_1, \dots, b_{N-1})$ deux séquences de longueur N , où les valeurs de a_k et b_k ne peuvent prendre que les valeurs $+1$ ou -1 . La fonction d'auto-corrélation aperiodique est définie par :

$$p_a(k) = \sum_{i=0}^{N-k-1} a_i a_{i+k}, \quad (1.48)$$

où $0 \leq k \leq N - 1$. La paire (a, b) est appelée une paire complémentaire de Golay si $p_a(k) + p_b(k) = 0$, pour tout k différent de 0. Chaque membre d'une paire complémentaire de Golay est une séquence complémentaire de Golay. Lorsqu'une telle séquence est utilisée pour former un symbole OFDM, il est possible de prouver que le signal temporel OFDM a alors un facteur de crête de $\sqrt{2}$ [Parker 03]. A noter que la longueur en échantillons d'une séquence complémentaire de Golay doit être de la forme $2^k 10^l 26^m$.

Les formes d'onde OFDM peuvent être particulièrement utiles en radar lorsque des échos fixes doivent être éliminés. En effet, les signaux OFDM donnent la possibilité d'appliquer une méthode de réjection des échos fixes de façon très simple [Poullin 05].

1.1.7 Pistage en radar

Jusqu'à présent nous nous sommes intéressés au traitement du signal radar dans l'optique d'effectuer l'estimation de la position de la cible, en l'absence de toute connaissance préalable sur la présence de la cible et de sa position passée. Or une fois la cible détectée et son état estimé, cette information peut être exploitée pour affiner l'estimation au cours des mesures ultérieures.

Le pistage en radar vise à estimer à chaque instant les paramètres de la trajectoire à partir de mesures bruitées fournies par le radar. Une trajectoire est formée non seulement de la position des cibles à un instant donné mais peut

également comporter des informations sur la vitesse et la direction de déplacement de chaque cible. Ces informations constituent ce que l'on appelle l'état de la cible. Son estimation repose classiquement sur une approche récursive visant à estimer la densité de probabilité a posteriori de l'état des cibles. Elle est tout d'abord prédite à partir du modèle d'état qui décrit l'évolution de la cible au cours du temps ; puis, elle est mise à jour lorsqu'une nouvelle mesure est disponible. Le pistage d'une ou de plusieurs cibles s'effectue généralement en utilisant des approches d'estimation bayésienne.

1.1.7.1 Représentation dans l'espace d'état

L'évolution du vecteur d'état de la cible $(\mathbf{x}_k)_{k \geq 0}$ au cours du temps qui correspond généralement à sa position et sa vitesse est décrite à partir d'un modèle de transition markovien, appelé équation d'état :

$$\mathbf{x}_k = f_k(\mathbf{x}_{k-1}, \mathbf{v}_k), \quad (1.49)$$

où f_k est la fonction de transition à l'instant k et \mathbf{v}_k est le bruit de modèle, dit bruit d'état. Le vecteur d'état \mathbf{x}_k prend ses valeurs dans l'espace d'état \mathbb{X} de dimension n_x , où $n_x \geq 1$ est le nombre de composantes considérées pour modéliser l'état de la cible.

Nous pouvons représenter l'évolution du vecteur d'état selon une distribution de transition de Markov notée $p(\mathbf{x}_k | \mathbf{x}_{k-1})$. L'objectif du pistage est d'estimer récursivement l'état de la cible \mathbf{x}_k à partir de la séquence de mesures reçues jusqu'à l'instant courant, notée $\mathbf{y}_{1:k}$.

Nous modélisons les mesures à partir de l'équation d'observation suivante :

$$\mathbf{y}_k = h_k(\mathbf{x}_k, \mathbf{w}_k), \quad (1.50)$$

où h_k est la fonction de mesure et \mathbf{w} est le bruit de mesure. Le vecteur de mesure \mathbf{y}_k prend ses valeurs dans l'espace d'observation \mathbb{Y} de dimension n_y , où $n_y \geq 1$ représente le nombre de paramètres fournis par la mesure radar.

Nous pouvons alors représenter la relation entre le vecteur d'état \mathbf{x}_k et le vecteur de mesure \mathbf{y}_k à partir de la vraisemblance conditionnelle $p(\mathbf{y}_k | \mathbf{x}_k)$. De plus, nous supposons l'indépendance temporelle entre les mesures reçues conditionnellement à l'état. Ainsi, la vraisemblance peut se décomposer comme suit :

$$p(\mathbf{y}_{1:k} | \mathbf{x}_{0:k}) = p(\mathbf{y}_k | \mathbf{x}_k) p(\mathbf{y}_{k-1} | \mathbf{x}_{k-1}) \dots p(\mathbf{y}_1 | \mathbf{x}_1). \quad (1.51)$$

Le filtrage dans un modèle d'état consiste à calculer la densité de probabilité a posteriori $p(\mathbf{x}_{0:k} | \mathbf{y}_{1:k})$ ou $p(\mathbf{x}_k | \mathbf{y}_{1:k})$. Théoriquement, la densité a posteriori $p(\mathbf{x}_k | \mathbf{y}_{1:k})$ peut être calculée récursivement à partir de deux équations formant le filtre de Bayes [Arulampalam 02].

1.1.7.2 Filtre de Bayes

La résolution du problème de filtrage ou plus particulièrement le calcul de la densité de probabilité a posteriori $p(\mathbf{x}_k|\mathbf{y}_{1:k})$ peut se faire de manière récursive en utilisant la formule de Bayes. Nous procédons en deux étapes : une étape de prédiction fondée sur le modèle d'état et une étape de correction qui prend en compte la mesure reçue à l'instant courant.

Prédiction : à chaque instant, la densité de probabilité prédite à l'instant k , notée $p(\mathbf{x}_k|\mathbf{y}_{1:k-1})$, est calculée à partir de la densité de probabilité a posteriori précédente en utilisant l'équation de Chapman-Kolmogorov :

$$p(\mathbf{x}_k|\mathbf{y}_{1:k-1}) = \int_{\mathbb{X}} p(\mathbf{x}_k|\mathbf{x}_{k-1})p(\mathbf{x}_{k-1}|\mathbf{y}_{1:k-1})d\mathbf{x}_{k-1}, \quad (1.52)$$

où la densité $p(\mathbf{x}_k|\mathbf{x}_{k-1})$ est fournie par le modèle d'état, et la densité $p(\mathbf{x}_{k-1}|\mathbf{y}_{1:k-1})$ est l'estimation fournie par le filtre à l'itération précédente.

Correction : l'étape de correction utilise alors la règle de Bayes et les indépendances conditionnelles pour prendre en compte l'information apportée par l'observation à l'instant k comme suit :

$$p(\mathbf{x}_k|\mathbf{y}_{1:k}) = \frac{p(\mathbf{y}_k|\mathbf{x}_k, \mathbf{y}_{1:k-1})p(\mathbf{x}_k|\mathbf{y}_{1:k-1})}{p(\mathbf{y}_k|\mathbf{y}_{1:k-1})} = \frac{p(\mathbf{y}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{y}_{1:k-1})}{p(\mathbf{y}_k|\mathbf{y}_{1:k-1})}. \quad (1.53)$$

Ainsi, si la densité de probabilité de l'état à l'instant initial $p(\mathbf{x}_0)$ est connue, le filtre de Bayes permet de calculer récursivement la densité de probabilité de l'état du système à chaque instant à partir des équations (1.52) et (1.53). Sa mise en œuvre nécessite néanmoins de calculer des intégrales multidimensionnelles. Or, cela n'est pas toujours réalisable ou alors seulement sous certaines conditions. Dans le cas où le modèle d'état et le modèle de mesure sont linéaires et les lois $p(\mathbf{x}_k|\mathbf{x}_{k-1})$, $p(\mathbf{y}_k|\mathbf{x}_k)$ et $p(\mathbf{x}_0)$ sont gaussiennes, la densité de probabilité a posteriori est gaussienne. On dispose alors d'expressions exactes au travers de l'algorithme du filtre de Kalman. Dans les autres cas, il est nécessaire de recourir à des approximations soit par des méthodes analytiques faisant intervenir une simplification du modèle (par exemple une linéarisation des modèles dans le cas non linéaire), soit par des méthodes numériques fondées sur une discrétisation de l'espace d'état ou encore par des méthodes de Monte Carlo. Dans la suite, nous présentons le filtre de Kalman et le filtre particulaire, deux types de filtres utilisés en pistage radar.

1.1.7.3 Filtre de Kalman

Le filtre de Kalman a été développé par R. E. Kalman en 1960 [Kalman 60]. Il constitue un cas particulier du filtre de Bayes où les équations (1.52) et (1.53)

peuvent être résolues exactement. Il constitue l'approche exacte de la récursion bayésienne dans le cas où f_k et h_k définies respectivement en (1.49) et (1.50) sont supposées linéaires et les bruits \mathbf{v}_k et \mathbf{w}_k sont supposés additifs gaussiens [Ho 64]. L'équation d'état et l'équation d'observation sont alors linéaires et peuvent s'écrire sous la forme :

$$\begin{cases} \mathbf{x}_k = \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{v}_k, \\ \mathbf{y}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{w}_k, \end{cases} \quad (1.54)$$

où

- \mathbf{F}_k et \mathbf{H}_k sont des matrices déterministes et connues. Elles sont de dimension $n_x \times n_x$ et $n_y \times n_x$ respectivement.
- Les bruits \mathbf{v}_k et \mathbf{w}_k sont supposés mutuellement indépendants et indépendants de la condition initiale \mathbf{x}_0 . Ils sont gaussiens de moyenne \mathbf{B}_k et \mathbf{D}_k respectivement et de matrices de covariance \mathbf{Q}_k et \mathbf{R}_k respectivement. Leurs densités de probabilité sont fournies par :

$$\begin{cases} p(\mathbf{v}_k) = \mathcal{N}(\mathbf{v}_k; \mathbf{B}_k, \mathbf{Q}_k), \\ p(\mathbf{w}_k) = \mathcal{N}(\mathbf{w}_k; \mathbf{D}_k, \mathbf{R}_k), \end{cases} \quad (1.55)$$

où $\mathcal{N}(\mathbf{x}; \mu, \Sigma)$ est la densité de probabilité gaussienne de la variable \mathbf{x} de moyenne μ et de matrice de covariance Σ .

- La loi initiale $p(\mathbf{x}_0)$ est gaussienne de moyenne $E[\mathbf{x}_0] = \mathbf{x}_{0|0}$ et de matrice de covariance $\mathbf{P}_{0|0}$.

Avec les hypothèses mentionnées, il est montré que le couple $(\mathbf{x}_k, \mathbf{y}_k)$ est gaussien et la loi a posteriori $p(\mathbf{x}_k | \mathbf{y}_{1:k})$ est gaussienne. Cette dernière densité à l'instant k est de moyenne $\mathbf{x}_{k|k}$ et de matrice de covariance $\mathbf{P}_{k|k}$.

La densité de transition et la vraisemblance de la mesure sont respectivement données par :

$$\begin{cases} p(\mathbf{x}_k | \mathbf{x}_{k-1}) = \mathcal{N}(\mathbf{x}_k; \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{B}_k, \mathbf{Q}_k), \\ p(\mathbf{y}_k | \mathbf{x}_k) = \mathcal{N}(\mathbf{y}_k; \mathbf{H}_k \mathbf{x}_k + \mathbf{D}_k, \mathbf{R}_k). \end{cases} \quad (1.56)$$

L'estimation de l'état prédit $\mathbf{x}_{k|k-1}$ et l'estimation de l'état a posteriori \mathbf{x}_k peuvent être fournies par : $\mathbf{x}_{k|k-1} = \mathbb{E}[\mathbf{x}_k | \mathbf{y}_{1:k-1}]$ et $\mathbf{x}_{k|k} = \mathbb{E}[\mathbf{x}_k | \mathbf{y}_{1:k}]$ [Bar-Shalom 04].

Prédiction : Supposons que l'estimation est faite à l'instant $k-1$, la densité a posteriori est de la forme :

$$p(\mathbf{x}_{k-1} | \mathbf{y}_{1:k-1}) = \mathcal{N}(\mathbf{x}_{k-1}; \mathbf{x}_{k-1|k-1}, \mathbf{P}_{k-1|k-1}), \quad (1.57)$$

avec $\mathbf{P}_{k-1|k-1}$ la matrice de covariance de la densité de probabilité a posteriori de \mathbf{x}_{k-1} qui est également la matrice de covariance de l'erreur d'estimation a posteriori à l'instant $k-1$.

La prédiction récursive bayésienne représentée par l'équation (1.52) peut être calculée [Tanizaki 13] et fournit la densité de probabilité prédite à l'instant k :

$$p(\mathbf{x}_k | \mathbf{y}_{1:k-1}) = \mathcal{N}(\mathbf{x}_k; \mathbf{x}_{k|k-1}, \mathbf{P}_{k|k-1}), \quad (1.58)$$

avec

$$\begin{cases} \mathbf{x}_{k|k-1} = \mathbf{F}_k \mathbf{x}_{k-1|k-1} + \mathbf{B}_k, \\ \mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{Q}_k. \end{cases} \quad (1.59)$$

Correction : La correction de la densité de probabilité de l'état du système peut être effectuée selon la règle de Bayes énoncée en Eq.(1.53). La vraisemblance conditionnelle s'écrit :

$$p(\mathbf{y}_k | \mathbf{x}_k) = \mathcal{N}(\mathbf{y}_k; \mathbf{H}_k \mathbf{x}_k + \mathbf{D}_k, \mathbf{R}_k). \quad (1.60)$$

Puis, en intégrant (1.58) et (1.60) dans (1.53), nous obtenons :

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) \propto \mathcal{N}(\mathbf{y}_k; \mathbf{H}_k \mathbf{x}_k + \mathbf{D}_k, \mathbf{R}_k) \mathcal{N}(\mathbf{x}_k; \mathbf{x}_{k|k-1}, \mathbf{P}_{k|k-1}). \quad (1.61)$$

Il apparaît donc que la loi de \mathbf{x}_k conditionnellement à $\mathbf{y}_{1:k}$ est gaussienne et en identifiant les termes de la relation (1.61) avec l'expression suivante :

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) = \mathcal{N}(\mathbf{x}_k; \mathbf{x}_{k|k}, \mathbf{P}_{k|k}), \quad (1.62)$$

nous obtenons

$$\begin{cases} \mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_k \left(\mathbf{y}_k - \left(\mathbf{H}_k \mathbf{x}_{k|k-1} + \mathbf{D}_k \right) \right) \\ \mathbf{P}_{k|k} = [\mathbf{I} - \mathbf{K}_k \mathbf{H}_k] \mathbf{P}_{k|k-1} \\ \mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \left[\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \right]^{-1}. \end{cases} \quad (1.63)$$

La matrice \mathbf{K}_k est appelée le gain de Kalman. Elle est dénommée ainsi car elle représente le gain de l'information nouvelle $\mathbf{y}_k - \left(\mathbf{H}_k \mathbf{x}_{k|k-1} + \mathbf{D}_k \right)$ apportée par la mesure sur \mathbf{y}_k par rapport à la prédiction $\mathbf{x}_k | \mathbf{x}_{k-1}$.

Le filtre de Kalman fournit donc l'estimateur optimal de \mathbf{x}_k au sens du minimum de l'erreur quadratique moyenne d'approximation de \mathbf{x}_k en fonction de $\mathbf{y}_{1:k}$ (i.e. $E\{\mathbf{x}_k | \mathbf{y}_{1:k}\}$) pour les modèles linéaires et gaussiens. Par ailleurs, lorsque les systèmes ne sont plus linéaires, il existe aussi des versions sous-optimales de cette solution. Le filtre de Kalman étendu (Extended Kalman Filter - EKF) utilise une linéarisation d'un système gaussien à partir d'un développement de Taylor et donne de très bons résultats avec faible complexité calculatoire dans le cadre des systèmes faiblement non-linéaires [Athans 68]. Pour des non-linéarités plus importantes, le filtre de Kalman sans parfum (Unscented Kalman filter - UKF) échantillonnant le système non-linéaire d'une

manière déterministe peut être utilisé [Wan 01]. Si les systèmes sont linéaires mais non gaussiens, un filtre du type somme de gaussiennes (Gaussian Sum Filter-GSF) [Ito 00] remplace l'hypothèse gaussienne par une somme pondérée des gaussiennes. Dans le cas d'hypothèses fortement non-linéaires et/ou non gaussiennes, ces différentes solutions peuvent toutefois être mises en défaut. Il est alors possible d'utiliser le filtre particulaire présenté ci-après.

1.1.7.4 Filtre particulaire

Nommé bootstrap filter [Gordon 93] ou Monte Carlo filter [Kitagawa 96] ou encore condensation filter [MacCormick 00], le filtre particulaire est fondé sur l'utilisation de méthodes de Monte-Carlo séquentielles (SMC) permettant d'approcher la densité $p(\mathbf{x}_{0:k}|\mathbf{y}_{1:k})$ par la loi empirique pondérée d'un ensemble d'échantillons appelés particules. Ces particules évoluent selon la dynamique de l'état et sont pondérées en fonction de leur adéquation avec l'observation courante grâce à la fonction de vraisemblance. L'intérêt de telles méthodes est l'absence de contrainte quant aux conditions de gaussianité et de linéarité sur les modèles d'état et de mesure.

Notons $\{\mathbf{x}_{0:k}^{(i)}, w_k^{(i)}\}_{i=1}^N$ un nuage de particules pondérées servant à estimer la densité a posteriori $p(\mathbf{x}_{0:k}|\mathbf{y}_{1:k})$, où les $\{\mathbf{x}_{0:k}^{(i)}, i = 1, \dots, N\}$ représentent les états des différentes particules avec les poids associés $\{w_k^{(i)}, i = 1, \dots, N\}$. Les poids sont normalisés pour que $\sum_{i=1}^N w_k^{(i)} = 1$. La densité a posteriori à l'instant k peut s'exprimer approximativement par

$$p(\mathbf{x}_{0:k}|\mathbf{y}_{1:k}) \approx \sum_{i=1}^N w_k^{(i)} \delta_{\mathbf{x}_{0:k}^{(i)}}(\mathbf{x}_{0:k}). \quad (1.64)$$

Les poids $w_k^{(i)}$ sont choisis en utilisant le principe d'échantillonnage d'importance [Doucet 01] : si les échantillons $x_{0:k}^{(i)}$ sont générés selon une densité d'importance $q(\mathbf{x}_{0:k}|\mathbf{y}_{1:k})$, les poids sont fournis par :

$$w_k^{(i)} \propto \frac{p(\mathbf{x}_{0:k}^{(i)}|\mathbf{y}_{1:k})}{q(\mathbf{x}_{0:k}^{(i)}|\mathbf{y}_{1:k})}. \quad (1.65)$$

A la réception de l'observation courante \mathbf{y}_k , nous avons à disposition un ensemble d'échantillons fournissant une approximation de $p(\mathbf{x}_{0:k-1}|\mathbf{y}_{1:k-1})$, et nous voulons construire de nouveaux échantillons fournissant une approximation de $p(\mathbf{x}_{0:k}|\mathbf{y}_{1:k})$. En choisissant une densité d'importance qui se factorise de la manière suivante :

$$q(\mathbf{x}_{0:k}|\mathbf{y}_{1:k}) = q(\mathbf{x}_k|\mathbf{x}_{0:k-1}, \mathbf{y}_{1:k})q(\mathbf{x}_{0:k-1}|\mathbf{y}_{1:k-1}), \quad (1.66)$$

un échantillon $\mathbf{x}_{0:k}^{(i)} \sim q(\mathbf{x}_{0:k}|\mathbf{y}_{1:k})$ est obtenu par concaténation de chaque échantillon existant $\mathbf{x}_{0:k-1}^{(i)} \sim q(\mathbf{x}_{0:k-1}|\mathbf{y}_{1:k-1})$ avec un nouvel état $x_k^{(i)} \sim q(\mathbf{x}_k|\mathbf{x}_{0:k-1}, \mathbf{y}_{1:k})$.

Il est possible de montrer que l'équation de mise à jour des poids s'écrit alors [Arulampalam 02] :

$$w_k^{(i)} \propto w_{k-1}^{(i)} \frac{p(\mathbf{y}_k|\mathbf{x}_{0:k}, \mathbf{y}_{1:k-1})p(\mathbf{x}_k^{(i)}|\mathbf{x}_{k-1}^{(i)})}{q(\mathbf{x}_k|\mathbf{x}_{0:k-1}, \mathbf{y}_{1:k})}. \quad (1.67)$$

Si les observations sont indépendantes conditionnellement au processus d'état et leurs distributions ne dépendent que de l'état courant, l'équation précédente peut s'écrire :

$$w_k^{(i)} \propto w_{k-1}^{(i)} \frac{p(\mathbf{y}_k|\mathbf{x}_k^{(i)})p(\mathbf{x}_k^{(i)}|\mathbf{x}_{k-1}^{(i)})}{q(\mathbf{x}_k|\mathbf{x}_{0:k-1}, \mathbf{y}_{1:k})}. \quad (1.68)$$

Par ailleurs, il est intéressant d'imposer $q(\mathbf{x}_k|\mathbf{x}_{0:k-1}, \mathbf{y}_{1:k}) = q(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{y}_k)$. Ce choix est particulièrement utile dans le cas où seule l'estimation de $p(\mathbf{x}_k|\mathbf{y}_{1:k})$ est requise à chaque l'instant k . Il n'est alors nécessaire que de stocker $\mathbf{x}_k^{(i)}$, la trajectoire $\mathbf{x}_{0:k-1}^{(i)}$ et les anciennes mesures $\mathbf{y}_{1:k-1}$ n'étant plus utiles. Les poids modifiés deviennent alors :

$$w_k^{(i)} \propto w_{k-1}^{(i)} \frac{p(\mathbf{y}_k|\mathbf{x}_k^{(i)})p(\mathbf{x}_k^{(i)}|\mathbf{x}_{k-1}^{(i)})}{q(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{y}_k)}, \quad (1.69)$$

et la densité a posteriori $p(\mathbf{x}_k|\mathbf{y}_{1:k})$ peut alors être approchée par :

$$p(\mathbf{x}_k|\mathbf{y}_{1:k}) \approx \sum_{i=1}^N w_k^{(i)} \delta_{\mathbf{x}_k^{(i)}}(\mathbf{x}_k). \quad (1.70)$$

Quand le nombre de particules devient très grand, $N \rightarrow +\infty$, l'approximation (1.70) se rapproche de la vraie densité de probabilité a posteriori $p(\mathbf{x}_k|\mathbf{y}_{1:k})$.

La mise en œuvre récursive de l'échantillonnage d'importance à chaque instant constitue la méthode d'échantillonnage d'importance séquentiel (Sequential Importance Sampling - SIS en anglais). Le filtrage à partir de l'algorithme SIS constitue la brique de base du filtre particulaire. Cependant, il est sujet à un phénomène de dégénérescence, où après quelques itérations, toutes les particules sauf une, vont avoir des poids normalisés négligeables. Il a été démontré que la variance des poids d'importance ne peut qu'augmenter avec le temps [Doucet 01] et qu'il est donc impossible d'éviter le phénomène de dégénérescence. Ainsi, cette dégénérescence implique qu'un grand coût de calcul est consacré à la mise à jour de particules dont la contribution à l'approximation de $p(\mathbf{x}_k|\mathbf{y}_{1:k})$ est quasi nulle. Afin de limiter cette dégénérescence, il existe deux méthodes : a) un bon choix de la densité d'importance et b) l'utilisation du ré-échantillonnage.

Choix de la densité d'importance

Le choix optimal de la densité d'importance au sens où il minimise la variance des poids est donné par [Doucet 01] :

$$q(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k}) = p(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k}). \quad (1.71)$$

Dans ce cas, les poids d'importance sont mis à jour par :

$$w_k^{(i)} \propto w_{k-1}^{(i)} p(\mathbf{y}_k | \mathbf{x}_{k-1}^{(i)}) = w_{k-1}^{(i)} \int_{\mathbb{X}} p(\mathbf{z}_k | \mathbf{x}'_k) p(\mathbf{x}'_k | \mathbf{x}_{k-1}^{(i)}) d\mathbf{x}'_k. \quad (1.72)$$

L'utilisation de cette densité d'importance optimale implique d'être capable d'échantillonner selon $p(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k})$ et puis d'évaluer l'intégrale dans l'équation (1.72). Ces deux étapes ne sont pas toujours réalisables : il n'est pas toujours facile d'échantillonner selon la loi $p(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k})$ et l'intégrale de l'équation (1.72) n'est pas toujours calculable.

En pratique, il est souvent convenable de choisir la densité d'importance comme la densité de transition a priori, soit :

$$q(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k}) = p(\mathbf{x}_k | \mathbf{x}_{k-1}). \quad (1.73)$$

L'intérêt est que les poids sont alors mis à jour simplement par :

$$w_k^{(i)} \propto w_{k-1}^{(i)} p(\mathbf{y}_k | \mathbf{x}_{k-1}^{(i)}). \quad (1.74)$$

Cela semble être le choix le plus commun de densité d'importance car il est intuitif et simple à mettre en œuvre. Cependant, un grand nombre de particules peut alors être nécessaire pour approcher convenablement la densité de probabilité a posteriori car les particules sont propagées indépendamment de la mesure courante et peuvent se retrouver localisées en majorité dans des régions de faible vraisemblance de l'espace d'état.

Ré-échantillonnage

L'idée de base du ré-échantillonnage est d'éliminer les particules de faible poids et de se concentrer sur les particules de poids important. L'étape de ré-échantillonnage est appliquée lorsqu'une dégénérescence significative est observée. Une mesure appropriée de cette dégénérescence est le nombre d'échantillons efficaces, introduite dans [Liu 98] et définie comme :

$$N_{eff} = \frac{N}{1 + \text{Var}(w_k^*)}, \quad (1.75)$$

où $w_k^* = p(\mathbf{x}_k | \mathbf{y}_{1:k}) / q(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{y}_k)$ est appelé le vrai poids. Comme on ne peut pas calculer explicitement cette valeur, elle est approchée par :

$$\hat{N}_{eff} = \frac{1}{\sum_{i=1}^N (w_k^i)^2}, \quad (1.76)$$

où w_k^i est le poids normalisé obtenu par (1.68).

Par définition, $1 \leq N_{eff} \leq N$. Une valeur faible de N_{eff} signifie une forte dégénérescence. Le rééchantillonnage est alors déclenché lorsque N_{eff} descend en dessous d'un certain seuil prédéfini. Cette étape consiste à générer un nouvel ensemble $\{\mathbf{x}_k^{(i)*}\}_{i=1}^N$ en tirant N particules à partir de l'approximation discrète de $p(\mathbf{x}_k, \mathbf{y}_{1:k})$ fournie par :

$$p(\mathbf{x}_k, \mathbf{y}_{1:k}) \approx \sum_{i=1}^N w_k^{(i)} \delta_{\mathbf{x}_k^{(i)}}(\mathbf{x}_k). \quad (1.77)$$

Les poids sont alors réinitialisés à $w_k^i = 1/N$. Un exemple du principe du filtre particulaire avec cette étape de ré-échantillonnage est montré en figure 1.1.6.




FIGURE 1.1.6 – Principe général du filtre particulaire.

Bien que le ré-échantillonnage atténue le phénomène de dégénérescence, il introduit un effet indésirable. Les particules de poids importants sont statistiquement sélectionnées plusieurs fois, ce qui a tendance à appauvrir le système de particules, surtout si la variance du bruit d'état est faible. Les particules ont dans ce cas tendance à se concentrer dans certaines régions, provoquant une perte de diversité. Cela augmente le risque qu'aucune des particules ne soit cohérente avec les mesures suivantes, provoquant ainsi la divergence du filtre. Un tel phénomène peut être en partie corrigé en ajoutant une étape de régularisation lors du ré-échantillonnage [Musso 01].

L'utilisation du filtre particulaire sera étudiée en détail dans le cadre de notre application particulière au chapitre 3.

1.2 Radar en milieu urbain

Cette section vise à présenter les problèmes de détection, de localisation et de pistage pour les applications radar en milieu urbain. Dans les scènes urbaines, des bâtiments peuvent générer d'une part des zones d'ombre à l'intérieur desquelles une cible n'est pas en visibilité directe, et d'autre part de nombreux multi-trajets produits par les réflexions et diffractions sur les surfaces environnantes. Lorsque la cible est localisée dans les zones d'ombre, elle n'est pas directement détectable par le radar puisque le trajet direct radar-cible n'existe pas. Dans un tel contexte, les multi-trajets peuvent alors être exploités afin de détecter et localiser la cible.

Dans un premier temps, nous présentons les défis rencontrés en milieu urbain comme la présence de multi-trajets (paragraphe 1.2.1) et le problème d'élimination des échos fixes issus des murs environnants (paragraphe 1.2.2). Ensuite, nous présentons l'état de l'art du problème du radar en milieu urbain : les techniques classiques utilisées en radar aéroporté comme GMTI ou SAR (paragraphe 1.2.4) et la problématique plus récemment abordée du radar « around-the-corner » où le radar est placé lui même dans le milieu urbain (paragraphe 1.2.5). C'est cette dernière application qui fait l'objet de cette thèse.

1.2.1 Multi-trajets

En milieu urbain, le signal émis par un radar peut être réfléchi ou diffracté par les bâtiments environnants. Selon la configuration géométrique, le signal réfléchi peut alors atteindre des zones initialement non illuminées par l'émetteur. Ce phénomène est d'autant plus important que le signal subit plusieurs réflexions. Il est alors possible que l'onde émise atteigne une cible en NLOS puis revienne au radar, ou bien que l'onde revienne au radar par un jeu de réflexions sur les murs seuls, créant ainsi des échos fixes. Si le radar est fixe, les échos fixes sont de Doppler nul, tandis que la cible mobile renvoie un signal à Doppler potentiellement non nul. Le signal reçu s'écrit donc comme la somme de ces différentes contributions :

$$y(t) = \underbrace{\sum_{n=1}^{M_f} \alpha_n s(t - \tau_n)}_{\text{échos fixes}} + \underbrace{\sum_{k=1}^{M_c} \alpha_k s(t - \tau_k) \exp(j2\pi f_0 \nu_k t)}_{\text{contributions de la cible}} + n(t), \quad (1.1)$$

où α_n et α_k , τ_n et τ_k sont les amplitudes complexes et les retards des différents multi-trajets des échos fixes et de la cible respectivement ; ν_k est le décalage

Doppler des multi-trajets de la cible ; M_f et M_c sont le nombre de trajets correspondant aux échos fixes et à la cible respectivement, et $n(t)$ est le bruit, supposé blanc gaussien complexe circulaire.

Ces multi-trajets représentent généralement un défi dans les applications classiques. Par exemple, ils produisent des canaux sélectifs en fréquence dans les applications de télécommunication. Dans d'autres cas, selon l'utilisation, ces multi-trajets peuvent être exploités à l'avantage du radar, par exemple, afin d'accroître les performances des systèmes radar MIMO multistatistiques (Multiple Input Multiple output) [Foschini 98, Telatar 99].

1.2.2 Élimination des échos fixes

Un des problèmes en milieu urbain est donc la présence des échos fixes. Ces échos sont souvent forts et peuvent masquer les contributions de la cible. Une élimination des échos fixes est nécessaire afin de faire ressortir les échos plus faibles issus de la cible. Dans l'étude [Rabaste 15], les échos fixes sont éliminés par soustraction au signal reçu d'un signal de référence préenregistré en l'absence de la cible. Cette méthode nécessite une mesure préalable de l'environnement en supposant que l'environnement ne varie pas dans le temps. Cette hypothèse très forte n'est pas envisageable pour notre application. Si le radar est fixe et que la cible est mobile, alors les échos fixes de l'environnement sont à Doppler nul tandis que les contributions de la cible sont de Doppler non-nul. Éliminer les échos fixes forts revient alors à éliminer les contributions de Doppler nul. Dans ce cas, il est possible d'appliquer une méthode basée sur une projection orthogonale au sous-espace des Doppler nuls, comme par exemple proposée par [Colone 09]. Cela consiste à chercher le vecteur d'amplitude $\hat{\mathbf{w}}$ qui minimise le problème :

$$\hat{\mathbf{w}} = \underset{\mathbf{w}}{\operatorname{argmin}} \|\mathbf{y} - \mathbf{X}_{\mathcal{M}}\mathbf{w}\|^2, \quad (1.2)$$

où $\mathbf{X}_{\mathcal{M}}$ est une matrice dont la colonne k est fournie par la version retardée $\mathbf{s}(\tau_k)$ du signal transmis \mathbf{s} . La taille de la matrice $\mathbf{X}_{\mathcal{M}}$ est $N_s \times N_{\mathcal{M}}$, où N_s est la longueur du vecteur \mathbf{s} et $N_{\mathcal{M}}$ est le nombre d'hypothèses de retards τ_k considérées. Classiquement, quand la matrice $\mathbf{X}_{\mathcal{M}}^H \mathbf{X}_{\mathcal{M}}$ est inversible, la solution du problème ci-dessus est donnée par :

$$\hat{\mathbf{w}} = (\mathbf{X}_{\mathcal{M}}^H \mathbf{X}_{\mathcal{M}})^{-1} \mathbf{X}_{\mathcal{M}}^H \mathbf{y}, \quad (1.3)$$

et le signal après la réjection est donc :

$$\begin{aligned} \mathbf{y}_{rej} &= \mathbf{y} - \mathbf{X}_{\mathcal{M}} (\mathbf{X}_{\mathcal{M}}^H \mathbf{X}_{\mathcal{M}})^{-1} \mathbf{X}_{\mathcal{M}}^H \mathbf{y} \\ &= \left(\mathbf{I} - \mathbf{X}_{\mathcal{M}} (\mathbf{X}_{\mathcal{M}}^H \mathbf{X}_{\mathcal{M}})^{-1} \mathbf{X}_{\mathcal{M}}^H \right) \mathbf{y}. \end{aligned} \quad (1.4)$$

D'autres méthodes sont également utilisées pour l'élimination des échos fixes en milieu urbain comme par soustraction adaptative [Zetik 06, Zetik 15], ou en émettant des rampes de fréquence dans [Johansson 14, Johansson 11], ou utilisant une caractéristique spécifique des formes d'ondes FMCW [Bosse 15] ou OFDM [Poullin 05].

1.2.3 Réflexions préliminaires sur le choix de la forme d'ondes

Les formes d'onde discutées au paragraphe 1.1.6 présentent des caractéristiques plus ou moins désirables pour des applications radar en général, et pour l'application radar around the corner en particulier. Nous nous proposons ici de les comparer brièvement. Pour cela, nous fixons la largeur de bande du signal à $B = 300$ MHz. Les critères de comparaison seront les suivants.

- Lobes secondaires :

Évaluer l'amplitude et la position des lobes secondaires de la fonction d'ambiguïté est une façon de qualifier les performances d'estimation pour une forme d'ondes dans le domaine temporel. Nous considérons les trois critères quantitatifs suivants dans le domaine temporel : niveau du premier lobe secondaire, niveau du lobe secondaire maximal et le rapport entre l'énergie totale des lobes secondaires et l'énergie du lobe principal (ISLR) (Tableau 1.1). Les valeurs des trois critères calculées à partir de l'auto-corrélation du signal doivent rester faibles pour limiter les problèmes d'ambiguïté et les problèmes de masquage des cibles faibles par les lobes secondaires des échos forts. Il apparaît dans ce tableau que les codes de phase SBLM et Zadoff-Chu fournissent les meilleures performances en terme de lobes secondaires, comme attendu puisqu'ils ont été créés pour limiter ces lobes secondaires. Le signal FMCW fournit des niveaux comparables à ceux fournis par les codes OFDM, avec toutefois un critère ISLR plus intéressant.

	FMCW	SBLM	Zadoff-Chu	OFDM aléatoire	OFDM Golay
Premier lobe (dB)	-13.27	-58.27	-45.50	-13.26	-13.27
Lobe maximal (dB)	-13.27	-37.28	-45.50	-13.26	-12.97
ISLR	-9.83	-5.03	-20.02	-3.25	-0.89

TABLE 1.1 – Comparaison des lobes secondaires de différentes formes d'onde.

- Spectre :

Le spectre souhaité pour un signal radar est un spectre présentant un niveau élevé (près de 0 dB) dans toute la bande passante et un faible niveau en dehors. Les différents spectres des codes étudiés sont présentés en figure 1.2.1. Nous

observons que le spectre des signaux OFDM est très propre : il est constant et à 0 dB dans toute la bande passante et très faible en dehors. Le spectre du signal FMCW suit la même tendance mais avec un niveau moins faible en dehors de la bande passante. Il présente par ailleurs des oscillations au bord de la bande passante. Enfin, les spectres des signaux de type codes de phase sont plus défavorables : ils s'approchent d'un sinus cardinal de sorte que l'amplitude n'est pas constante dans la bande d'intérêt, et qu'il y a des lobes secondaires forts en dehors de la bande, et donc une énergie hors bande importante qui doit être filtrée à l'émission, au risque de créer des distorsions potentiellement importantes du signal émis.

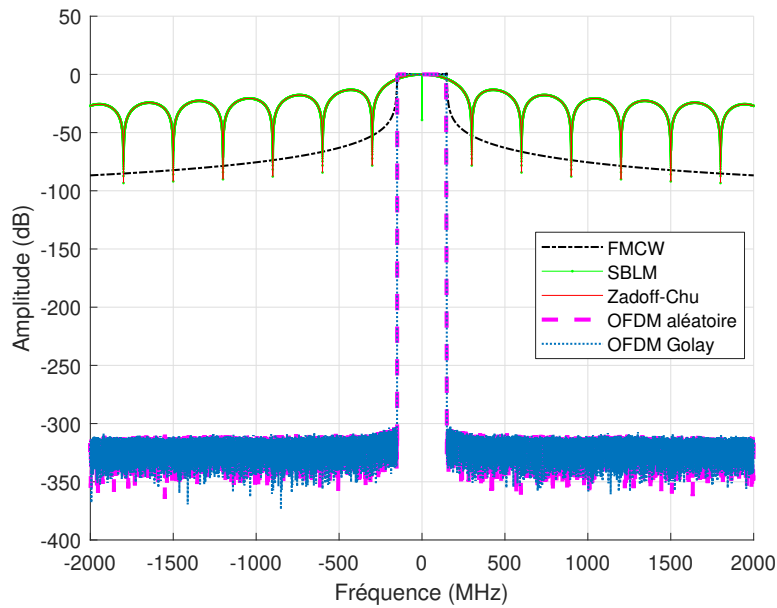


FIGURE 1.2.1 – Spectre de différentes formes d'onde.

- Facteur de crête :

Le facteur de crête est le rapport entre l'amplitude du pic maximal du signal $|x|_{\text{pic}}$ et la valeur efficace du signal x_{rms} : $C = |x|_{\text{pic}}/x_{\text{rms}}$. C'est une grandeur fondamentale pour le dimensionnement des amplificateurs. En effet, l'amplificateur devra être dimensionné par rapport au pic du signal. Cependant, la valeur efficace du signal est la valeur "utile" moyenne, celle qui va vraiment caractériser la puissance transmise, et c'est donc la valeur à maximiser. Le facteur de crête représente le rapport de surdimensionnement nécessaire entre la puissance maximale de l'amplificateur (la puissance pour laquelle il est dimensionné) et la puissance moyenne réellement transmise. Il est donc important de minimiser le facteur de crête, ce qui permet d'avoir des amplificateurs dimensionnés au plus juste par rapport à la puissance à transmettre.

Les signaux FMCW, SBLM et Zadoff-Chu étant des codes à amplitude constante, ils présentent un facteur de crête de 1 qui est optimal. Le signal OFDM aléatoire a un facteur de crête de plus de 3 généralement et celui de l'OFDM Golay est de $\sqrt{2}$. Du point de vue énergétique, le codage OFDM semble donc moins intéressant.

- Robustesse au Doppler :

Théoriquement, en radar, un signal est considéré comme robuste au Doppler lorsque l'énergie en sortie de filtre adapté ne baisse que très lentement lorsque le Doppler du signal reçu augmente. C'est le cas des signaux chirp classiquement utilisés en radar. Cette propriété est intéressante car elle permet de n'utiliser qu'un seul filtre adapté au Doppler nul à la réception pour effectuer la détection, même en présence d'un décalage Doppler important. Dans le cas contraire, il est nécessaire d'utiliser un banc de filtres afin que le signal reçu soit détecté dans au moins un filtre à la réception. La raison majeure reste donc bien liée au coût du récepteur et à la charge de calcul. Nous pouvons quantifier cette « robustesse au Doppler » en considérant la valeur maximale de la coupe à la fréquence ν de la fonction d'ambiguïté $|\chi(\tau, \nu)|$:

$$R(\nu) = \max_{\tau} (|\chi(\tau, \nu)|). \quad (1.5)$$

La figure 1.2.2 montre la courbe $R(\nu)$ de différentes formes d'onde dans un intervalle Doppler de 0 à 50 KHz. Dans toute la plage, le signal FMCW dont la courbe est proche de 0 dB est le plus robuste en Doppler. Remarquons que pour le problème du radar en milieu urbain, la vitesse des cibles n'est pas très significative. Par exemple, à $f_0 = 9,6$ GHz (figure 1.2.2), en considérant la vitesse maximale d'une cible à 30 m/s qui correspond à 1,92 KHz en décalage de fréquence Doppler, le gain observé n'est pas significatif pour la forme d'ondes FMCW par rapport aux autres.

Compte tenu de ces différentes analyses, nous constatons toutefois que la forme d'ondes FMCW semble fournir des performances satisfaisantes pour tous les critères examinés : spectre d'émission propre, simplicité de traitement à la réception et robustesse au Doppler.

1.2.4 Cibles en NLOS en aéroporté

La problématique des cibles NLOS en milieu urbain commence à être étudiée depuis quelques années pour les applications de radar aéroporté de type GMTI ou SAR. La faisabilité de l'exploitation de la propagation des multi-trajets en milieu urbain pour un radar aéroporté GMTI (Ground Moving Target Indicator) a été examinée par [Krolik 06]. Cette étude a montré qu'il est possible de tenir compte de la connaissance a priori des bâtiments et d'utiliser les multi-trajets NLOS pour prédire le déplacement des retours GMTI en distance et en

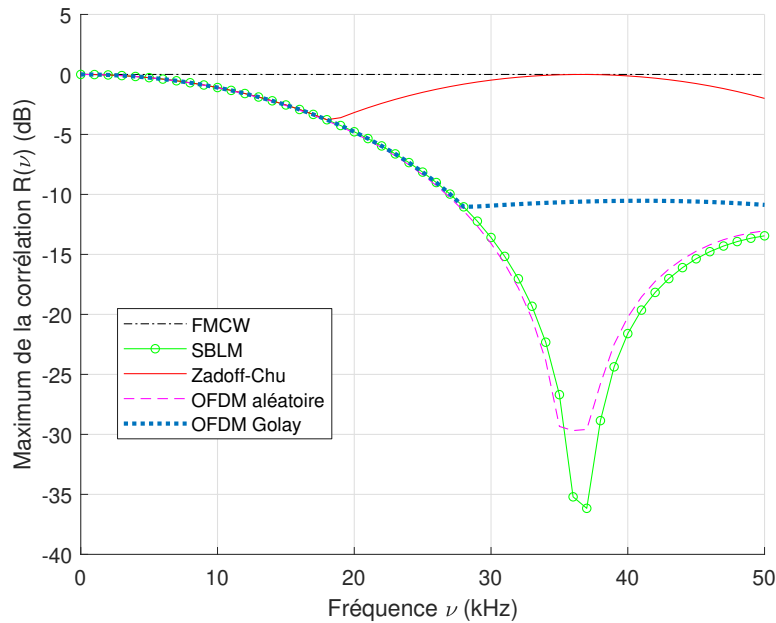


FIGURE 1.2.2 – Robustesse Doppler de différentes formes d'onde : $R(\nu) = \max_{\tau} (|\chi(\tau, \nu)|)$ pour $f_0 = 9,6$ GHz.

Doppler. Plus récemment, [Linnehan 09] a examiné la faisabilité de la détection et du pistage des cibles au sol en milieu urbain à l'aide du radar GMTI lorsque la couverture de la ligne de vue est intermittente, mais que des réponses par multi-trajets réfléchis par les murs des bâtiments environnants sont disponibles. Il ressort de cette étude que les réponses secondaires des multi-trajets, et l'énergie propagée en distance et en Doppler, pourraient être exploitées pour détecter les cibles masquées par les bâtiments.

La technique Synthetic Aperture Radar (SAR en anglais), soit Radar à Synthèse d'Ouverture (RSO en français) exploite le déplacement de l'antenne pour obtenir une antenne "de synthèse" de dimension plus importante, et donc une résolution angulaire bien supérieure à celle d'une antenne immobile. Le principe de l'imagerie SAR consiste à illuminer une zone du sol avec le faisceau d'ondes électromagnétiques de l'antenne pendant que le porteur se déplace sur sa trajectoire de vol. L'ensemble des données collectées par le radar va permettre d'établir l'image de terrain via un algorithme de reconstruction d'images.

Dans le milieu urbain, la présence des multi-trajets peut causer des artefacts dans l'image SAR formée qui en complique l'analyse, par exemple en donnant lieu à des points brillants mal localisés. Récemment, l'utilisation d'un radar SAR exploitant les multi-trajets pour détecter et localiser des cibles en milieu urbain a été développée dans [Setlur 14]. Deux techniques d'exploitation des

multi-trajets en absence de LOS pour détecter une cible à sa position réelle sont proposées sous l'hypothèse que les positions des murs réflecteurs sont connues et que les multi-trajets sont détectables et séparables. La première technique opère directement sur les signaux radar bruts, tandis que la seconde opère sur l'image formée par faisceau traditionnel. Ces deux techniques semblent atténuer les fausses alarmes tout en permettant à la cible masquée d'être détectée à sa vraie position.

1.2.5 Radar around-the-corner (RAC)

Dans l'application qui nous intéresse plus particulièrement dans le cadre de cette thèse, le radar around the corner, le capteur radar n'est plus aéroporté mais directement localisé dans le milieu urbain. Comme dans tous les problèmes en milieu urbain, des bâtiments de la scène génèrent d'une part des zones d'ombre à l'intérieur desquelles une cible n'est pas en visibilité directe, et d'autre part de nombreux trajets produits par les possibles réflexions et diffractions sur les surfaces environnantes. Or ces multi-trajets peuvent être exploités à l'avantage du radar afin de détecter et localiser des cibles situées dans les zones d'ombre. Il devient alors possible de regarder derrière les coins de murs au moyen d'un simple radar portatif : on parle alors de radar « around-the-corner » (RAC) [Sume 11].

1.2.5.1 Mesures réelles

Peu de littérature existe quant à la détection et la localisation de cibles en milieu urbain au moyen d'un radar localisé dans une rue adjacente. Toutefois, des travaux expérimentaux ont été menés pour tester la faisabilité de la détection et de la localisation en l'absence de LOS (NLOS) avec des mesures réelles [Sume 11] [Rabaste 15] [Tahmoush 12] [Gustafsson 16]. Par différentes expérimentations avec différentes configurations du radar et de la scène, ces études ont démontré qu'il est possible de détecter des multi-trajets issus de cibles localisées en NLOS. Par exemple, dans [Sume 11], il est démontré qu'il est possible de détecter une cible dans le domaine distance-fréquence Doppler, de suivre différents multi-trajets dans le domaine distance-temps ou d'observer des signatures Doppler de la respiration d'une personne. Dans [Gustafsson 16], les auteurs ont effectué plusieurs mesures dans des situations NLOS et se sont concentrés sur la signature micro-Doppler de la cible dans le but de classer des objets. En extrayant des informations sur les multi-trajets, les auteurs ont démontré que les caractéristiques micro-Doppler des personnes qui marchent peuvent être extraites des signaux reçus. Dans [Rabaste 15], les auteurs ont montré qu'il était possible de visualiser et expliquer au moyen d'un modèle de




FIGURE 1.2.3 – Un radar around-the-corner en milieu urbain.

propagation simple plusieurs multi-trajets issus de données réelles.

D'autres études ont porté plus spécifiquement sur la résolution du problème de détection, de localisation ou de pistage d'une ou de plusieurs cibles en milieu urbain.

1.2.5.2 Détection de cibles mobiles

Dans [Johansson 14], la détection des mouvements dans une scène réaliste a été étudiée. Dans cette étude, les auteurs ont appliqué un seuil adaptatif à la réponse impulsionnelle mesurée afin de trouver des points excédant le seuil, qui ont été considérés comme une détection. La méthode est relativement simple et facile à mettre en œuvre, mais les informations des différents trajets ont été traitées séparément. En effet, la méthode appliquée est le filtre adapté classique utilisé en traitement radar. Dans ce cas précis, seule l'information du trajet le plus fort est utilisée pour la détection de la cible.

1.2.5.3 Localisation d'une cible mobile

Dans la suite de leur recherche, dans [Johansson 17], ces mêmes auteurs ont proposé un algorithme de localisation d'une ou plusieurs cibles en mouvement

en exploitant les points de détection trouvés par l'étude précédente. Une simulation a été réalisée avec une antenne à faisceau étroit avec une largeur de lobe 3dB de $2,5^\circ$. En supposant que la géométrie de la scène est connue, la solution de localisation proposée reposait principalement sur deux informations : la distance de détection obtenue en appliquant un filtre adapté, et la connaissance de la direction du faisceau radar. Avec une direction de faisceau donnée, les positions des cibles peuvent en effet être facilement déduites à partir de la distance de détection par un simple modèle de tracé de rayons et un seul trajet. Des simulations ont démontré que les cibles peuvent être détectées et localisées avec peu de fausses localisations. Cette solution suppose que le radar peut fournir une résolution angulaire suffisamment petite pour couvrir toute la surface surveillée. Cependant, cette exigence n'est pas toujours respectée, ce qui peut entraîner des erreurs de localisation. D'autre part, il devient nécessaire de balayer tout l'espace angulaire, ce qui a un coût. De surcroît, les multi-trajets issus de différentes directions ne sont pas exploités simultanément, ce qui est sous optimal et peut conduire à des détections multiples du même objet.

Dans [Zetik 15], les auteurs ont proposé une estimation de la position d'une cible à partir d'un seul trajet réfléchi, un seul trajet diffracté et leurs combinaisons en utilisant un calcul géométrique. Les résultats expérimentaux ont montré que la position de la cible a été bien estimée lorsque des informations d'au moins deux trajets différents étaient disponibles. Cependant, les auteurs n'ont pas pris en compte deux ou plusieurs trajets de réflexion sur d'autres murs qui pourraient apparaître dans certaines scènes et qui pourraient potentiellement améliorer la localisation de la cible.

D'autres études récentes ont exploité des multi-trajets avec un seul capteur également à des fins de localisation uniquement [Setlur 12][Setlur 13][O'connor 15]. Dans ces travaux, les auteurs ont exploité l'information des multi-trajets en utilisant les mesures du temps d'arrivée (TOA). Ces algorithmes exploitent la sortie d'un filtre adapté classique. Ils ne fonctionnent pas directement avec les signaux bruts. L'étude [Setlur 12] exige que tous les trajets soient détectés et étiquetés comme des trajets directs ou à rebond unique, puis associés aux différents murs. Dans [O'connor 15], cette méthode a été étendue au radar passif dans le cas du double rebond où, en outre, certains trajets peuvent ne pas être détectés. Enfin, la position de la cible est déterminée par l'intersection des cercles et des ellipses caractérisés par les TOA. La performance de ces approches a été étudiée dans [Setlur 13]. Notons que le problème de la détection de cible n'a pas été pris en compte dans toutes les études sur la localisation mentionnées ci-dessus.

1.2.5.4 Pistage d'une cible mobile

Le suivi des cibles basé sur l'exploitation des multi-trajets a également été étudié via l'approche de pistage dans [Chakraborty 10] avec un radar aéroporté ou dans [Barbosa 08] avec des multi-émetteurs et multi-récepteurs présents dans la scène. Dans [Chakraborty 10], les auteurs se sont concentrés sur le problème de conception d'une forme d'onde adaptative pour le problème de pistage, alors que dans [Barbosa 08], une nouvelle chaîne de traitement des données mesurées par différents capteurs dans le but de suivre une cible le long de sa trajectoire est proposée. Cependant, ces deux études ne traitent pas le problème des ambiguïtés inhérentes à la propagation par multi-trajets, qui est un des problèmes majeurs en milieu urbain. Ces ambiguïtés sont constatées dans différentes études. Par exemple, dans [Setlur 14], où un SAR urbain est étudié, les deux techniques d'exploitation des multi-trajets proposées ont également fourni des images ambiguës, ou dans [Tahmoush 12], dans le but de suivre des cibles dans le domaine temps-distance en exploitant des multi-trajets, l'approche proposée n'a pas été en mesure d'éliminer l'ambiguïté de deux pistes de multi-trajets ayant un temps de propagation similaire.

1.3 Conclusion

Dans ce chapitre, nous avons dans un premier temps présenté les principes de bases du traitement du signal radar. En particulier, le filtre adapté a été présenté et son rôle fondamental dans la détection et l'estimation a été montré. Pour finir, nous avons présenté le pistage en traitement du signal radar classique en se focalisant sur deux types de filtres principaux : les filtres de type Kalman pour les systèmes linéaires et les filtres particuliers pour les systèmes non-linéaires.

Dans un second temps, nous avons présenté la problématique et l'état de l'art du radar en milieu urbain. Une problématique similaire rencontrée dans les domaines des traitements radar aéroportés SAR et GMTI, est étudiée depuis une dizaine d'années dans la littérature. Le cas du radar around-the-corner avec un radar localisé directement dans le milieu urbain est, quant à lui, très récent dans la littérature et n'a fait que peu l'objet de publications. Les premiers résultats issus de ces publications ont montré qu'il est possible de détecter, localiser ou pister une cible masquée (absence de LOS) avec un ou plusieurs radars. Les travaux effectués du point de vue du traitement restent pour l'instant relativement proches des traitements radar classiques et ne prennent pas nécessairement en compte les spécificités du problème. Tout l'objet de ce travail de thèse est donc d'étudier, de proposer et de développer des méthodes de

traitement dédiées à la détection et à la localisation d'une cible masquée en milieu urbain.

Chapitre 2

Algorithmes de détection et localisation en milieu urbain

2.1 Introduction

Dans le premier chapitre, nous avons décrit le problème du radar en milieu urbain. Notamment, des bâtiments dans la scène génèrent d'une part des zones d'ombre à l'intérieur desquelles une cible n'est pas en visibilité directe, et d'autre part de nombreux multi-trajets produits par les possibles réflexions et diffractions sur les surfaces environnantes. Ces multi-trajets peuvent être exploités à l'avantage du radar afin de détecter et localiser des cibles situées dans les zones d'ombre. Dans ce chapitre, nous étudions le problème de détection et de localisation en exploitant ces multi-trajets. En prenant en compte des multi-trajets, nous visons d'abord à améliorer la performance de détection par rapport au filtre adapté classique. Pour cela, nous avons développé deux algorithmes : un algorithme basé sur un détecteur adapté sous-espace [Scharf 94], et l'autre basé sur une intégration non cohérente de l'énergie des multi-trajets, ce qui est similaire à une technique utilisée en télécommunication, « square-law-combiner » [John 02]. Nous verrons que les méthodes proposées présentent de meilleures performances de détection quand l'information portée par les multi-trajets est suffisante. Par conséquent, nous proposons également de sélectionner le nombre de trajets de façon à maximiser la probabilité de détection. En appliquant une stratégie de type Maximum de Vraisemblance (MV), ces deux algorithmes sont également utiles pour le problème de localisation. Les performances de localisation de ces deux algorithmes sont analysées par des simulations dans ce chapitre ainsi que sur des données réelles dans le chapitre 4. Comme souligné dans le chapitre 1, la présence des ambiguïtés spatiales est un problème majeur de la localisation urbaine. Nous proposons

ensuite des améliorations apportées aux algorithmes de localisation afin de réduire ces ambiguïtés et donc améliorer la performance de localisation.




FIGURE 2.1.1 – Un radar urbain exploitant les réflexions pour détecter des cibles en NLOS.

Dans ce chapitre, le modèle du signal en milieu urbain est présenté dans la section 2.2. Nous rappelons le filtre adapté classique dans la section 2.3.1 et présentons la méthode des empreintes digitales dans la section 2.3.2. Nous proposons deux algorithmes pour la détection et localisation dans les sections 2.3.3 et 2.3.4; et les comparons en termes de performance de détection, de temps de calcul et de mémoire requise dans la section 2.3.5. Dans la section 2.4, nous proposons un algorithme pour la sélection du nombre de trajets pris en compte pour deux algorithmes détection-localisation proposés. Dans la section 2.5, nous présentons la simulation et les résultats de ces algorithmes proposés. Enfin, dans la section 2.6, nous discutons le problème des ambiguïtés et proposons des améliorations.

2.2 Modèle du signal en milieu urbain

Nous supposons que toutes les réflexions sont spéculaires pour la bande de fréquence considérée, que la diffraction peut être négligée, qu'une connaissance

approximative de la géométrie de la scène est disponible, et que la position GPS du radar est connue. Par le souci de simplicité, le problème de la détection-localisation d'une seule cible dans l'espace 2D (x, y) est considéré, nous ne supposons pas de localisation en hauteur (axe z). L'information Doppler est naturellement présente dans le signal et exploitée pour éliminer les échos fixes localisés à Doppler nul. Cependant, de nouveau dans un but de simplicité et à cause de la limitation de la configuration matérielle utilisée dans l'expérimentation réelle, nous n'exploiterons pas l'information Doppler des différents multi-trajets pour la détection-localisation de cible. Bien entendu, l'exploitation du Doppler pourrait être intéressante pour améliorer les performances de localisation de la solution proposée. Nous supposons également ici que les échos fixes forts produits par les bâtiments et les objets environnants ont déjà été supprimés, par exemple en appliquant une méthode de rejet à zéro Doppler basée sur [Colone 09] présentée dans le paragraphe 1.2.2, de sorte que les seuls échos reçus sont rétrodiffusés par des cibles mobiles proches.

Remarque concernant la diffraction : nous supposons dans tout ce qui suit que la diffraction peut être négligée pour la longueur d'onde considérée. En effet, dans l'application qui nous intéresse, les pertes subies par les trajets diffractés sont très importantes, comme le montre la figure 2.2.1, qui présente la perte de diffraction en fonction de la position de la cible pour le sommet localisé en $(13; 13)$, pour la géométrie considérée, et pour une fréquence de 24 GHz.




FIGURE 2.2.1 – Perte de diffraction obtenue par résolution de l'intégrale de Fresnel pour le problème de diffraction en lame de couteau (solution de Sommerfeld) [Sommerfeld 04].

Le signal $y(t)$ reçu par le radar peut s'écrire :

$$y(t) = \sum_{k=1}^{M(x,y)} \alpha_k s(t - \tau_k(x, y)) + n'(t), \quad (2.1)$$

où $s(t)$ est le signal transmis par le radar, $M(x, y)$ est le nombre de multi-trajets pour une cible située au point (x, y) , $\tau_k(x, y)$ et α_k sont respectivement le retard et l'amplitude du trajet k , $n'(t)$ est supposé être un bruit blanc circulaire gaussien complexe.

Les multi-trajets en milieu urbain peuvent être très proches en distance, par exemple de l'ordre de 1 mètre d'écart. Afin de séparer les différents multi-trajets, il est important d'utiliser un signal avec une bande passante suffisamment grande, typiquement plusieurs centaines de MHz. Cela implique une fréquence d'échantillonnage élevée. Par exemple, une résolution distance de 0,5 m nécessite une bande passante minimale de 300 MHz, donc une fréquence d'échantillonnage importante. Ainsi, une fois échantillonné, le signal reçu $y(t)$ peut contenir beaucoup d'échantillons (typiquement des milliers d'échantillons), bien que toutes les informations soient contenues dans quelques dizaines de cases de distance. L'application d'un filtre adapté permet de concentrer ces informations dans quelques cases distance et de supprimer les cases restantes inutiles, ce qui permet d'économiser du temps de calcul et de la mémoire. Si $z(t)$ désigne la sortie du filtre adapté appliqué à $y(t)$, nous avons alors :

$$z(t) = \sum_{k=1}^{M(x,y)} \alpha_k r(t - \tau_k(x, y)) + n(t), \quad (2.2)$$

où $r(t)$ est l'auto-corrélation de $s(t)$, et $n(t)$ est le bruit en sortie de filtre adapté.

Soit N le nombre d'échantillons temporels considérés en sortie de filtre adapté. Nous pouvons définir les vecteurs et matrices suivants :

$$\mathbf{r}(\tau) = [r(t_1 - \tau), \quad r(t_2 - \tau), \quad \dots, \quad r(t_N - \tau)]^T,$$

$$\mathbf{n} = [n(t_1), \quad n(t_2), \quad \dots, \quad n(t_N)]^T,$$

$$\mathbf{z} = [z(t_1), \quad z(t_2), \quad \dots, \quad z(t_N)]^T$$

$$\boldsymbol{\alpha} = [\alpha_1, \quad \alpha_2, \quad \dots, \quad \alpha_{M(x,y)}]^T,$$

$$\mathbf{R}(x, y) = [\mathbf{r}(\tau_1(x, y)), \quad \mathbf{r}(\tau_2(x, y)), \quad \dots, \quad \mathbf{r}(\tau_{M(x,y)}(x, y))].$$

L'équation (2.2) peut être alors réécrite comme :

$$\mathbf{z} = \mathbf{R}(x, y)\boldsymbol{\alpha} + \mathbf{n}, \quad (2.3)$$

où la matrice $\mathbf{R}(x, y)$ de taille $N \times M(x, y)$ contient alors les différentes versions retardées du signal reçu à la position (x, y) . Si nous supposons que la fréquence d'échantillonnage du signal est $f_c = 1/B$, avec B la bande du signal émis, et que le signal émis est de type chirp, alors l'auto-corrélation du signal est approximativement égale à un Dirac. Dans ce cas, \mathbf{n} est aussi un bruit circulaire gaussien complexe. La matrice de covariance du bruit est supposée égale à $\sigma^2 \mathbf{I}$ avec σ^2 connu.

2.3 Solutions de détection et localisation

2.3.1 Application du filtre adapté mono-trajet (FA)

Le traitement généralement appliqué dans les applications radar pour détecter les cibles est de comparer le filtre adapté à un seuil, qui correspond à un détecteur GLRT (Generalized Likelihood Ratio Test) mono-trajet. En effet, si nous considérons le test d'hypothèses suivant :

$$\begin{cases} H_0 : \mathbf{y} = \mathbf{n}, & \text{bruit,} \\ H_1 : \mathbf{y} = A\mathbf{s}(\tau) + \mathbf{n}, & \text{cible+bruit,} \end{cases} \quad (2.1)$$

où \mathbf{n} est un bruit blanc gaussien complexe circulaire, et l'amplitude A est supposée inconnue déterministe, alors le test de détection GLRT est fourni par :

$$\frac{|\mathbf{s}^H(\tau)\mathbf{y}|^2}{\mathbf{s}^H(\tau)\mathbf{s}(\tau)} \underset{H_0}{\overset{H_1}{\geq}} \lambda_{FA}, \quad (2.2)$$

qui correspond effectivement au filtre adapté au signal $\mathbf{s}(t)$ pour le retard τ . Le seuil de détection λ_{FA} peut être calculé en fonction de la variance du bruit σ^2 et de la probabilité de fausse alarme P_{FA} :

$$\lambda_{FA} = -\sigma^2 \ln P_{FA}. \quad (2.3)$$

Ce type de stratégie ne prend pas en compte la présence de multi-trajets, mais uniquement l'information d'un seul trajet. Elle est donc insuffisante pour localiser la cible dans le milieu urbain, car la détection d'un seul trajet ne fournit qu'une unique information de retard, et conduit donc à une ambiguïté de localisation importante.

2.3.2 Application de la méthode des empreintes digitales (ED)

Une méthode de localisation utilisée dans les applications de localisation à l'intérieur des bâtiments (« indoor ») est la méthode des empreintes digitales.

La localisation par empreintes digitales est une méthode de positionnement qui exploite les infrastructures déjà existantes telles que les réseaux cellulaires ou les réseaux WLAN [Takenga 07, Bahl 00]. La méthode tire parti des mesures radio standard disponibles à partir des technologies d'interface radio, et peut donc être considérée comme une méthode de positionnement à faible coût.

Généralement, le déploiement de systèmes de positionnement à base d'empreintes digitales peut être divisé en deux phases [Kaemarungsi 04]. Premièrement, dans la phase « offline », les empreintes digitales de localisation sont collectées en effectuant une recherche sur toute la zone considérée de l'intensité du signal reçu (RSS - received signal strength en anglais) à partir de plusieurs points d'accès. Toute la zone est couverte par une grille rectangulaire de points. La RSS est mesurée afin de créer une base de données ou une table de valeurs RSS prédéterminées sur les points de la grille. Le vecteur des valeurs RSS à un point de la grille s'appelle l'empreinte de localisation de ce point. Cette étape peut se faire par simulation si le modèle de propagation dans la zone est connu, ou par mesures réelles. Actuellement, il n'y a pas de lignes directrices pour choisir l'espacement de la grille. De plus, l'évaluation du nombre de points d'accès nécessaires pour obtenir une exactitude et une précision particulières n'est pas évidente [Kaemarungsi 04]. Deuxièmement, dans la phase « online », un vecteur de RSS est calculé en plusieurs points d'accès à partir d'une mesure contenant potentiellement une cible et fourni au serveur central. Le serveur utilise un algorithme pour estimer la position de la cible et rapporte l'estimation à l'application demandant l'information de position. L'algorithme le plus commun pour estimer la position calcule la distance euclidienne entre le vecteur RSS mesuré et chaque empreinte dans la base de données. Les coordonnées associées à l'empreinte qui fournissent la plus petite distance euclidienne sont renvoyées en tant qu'estimation de la position. D'autres algorithmes utilisent les réseaux de neurones [Smailagic 00] ou la modélisation bayésienne [Castro 01] pour relier le vecteur mesuré à l'empreinte de la base de données.

Dans notre contexte de radar en milieu urbain, nous considérons qu'un seul radar est présent dans la scène donnée. Contrairement à la méthode d'ED classique décrite ci-dessus dont les données pour les empreintes digitales sont mesurées par différents capteurs, nous n'avons donc qu'une seule mesure fournie par le radar. Nous pouvons toutefois exploiter les multi-trajets comme des empreintes digitales à la place de plusieurs points d'accès. Une étape supplémentaire est donc nécessaire, qui consiste à exploiter des informations des multi-trajets à partir du signal brut afin de créer les empreintes digitales. Les informations des multi-trajets ici peuvent être leurs retards et/ou leurs amplitudes. Toutefois, dans notre cas précis, nous ne connaissons pas le modèle d'amplitude de manière fiable : un tel modèle dépend fortement de la géomé-

trie de la scène, des matériaux des réflecteurs, de la cible elle-même et de son orientation, etc. Par conséquent, l'étape de formation des empreintes digitales nécessiterait des mesures réelles de la scène, ce qui n'est pas réaliste dans notre cas. Il est donc préférable de ne pas exploiter l'amplitude ici.

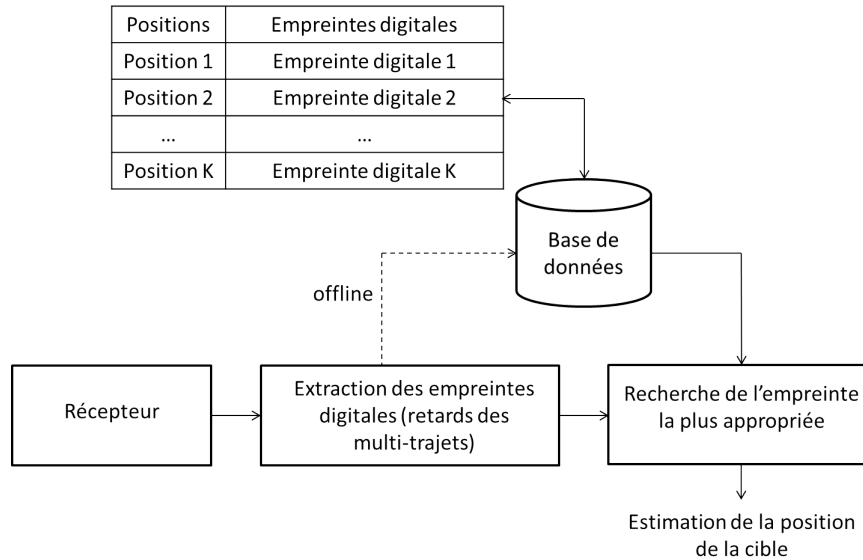


FIGURE 2.3.1 – Schéma de principe de la méthode des empreintes digitales.

Nous proposons donc une application de la méthode des empreintes digitales comme résumée par le schéma de la figure 2.3.1. Dans la phase « off-line », la zone observée est discrétisée en petites cases positions. Pour chaque case position (x, y) , les retards des multi-trajets sont calculés par une simulation de tracé de rayons. Ces retards sont utilisés pour former l'empreinte digitale correspondant à la position (x, y) , empreinte créée sous la forme d'un vecteur $\mathbf{e}(x, y)$ composé de 0s et 1s : chaque entrée de $\mathbf{e}(x, y)$ correspond à des retards échantillonnés, pour chaque retard τ_i , l'élément $[\tau_i/T_s]$ prend la valeur 1 tandis que les autres éléments sont laissés à 0, T_s correspondant à la période d'échantillonnage (comme illustré en figure 2.3.2). Dans la phase on-line, le signal reçu en sortie de filtre adapté est seuillé pour détecter les multi-trajets : les retards correspondant aux pics de détection sont stockés dans un vecteur \mathbf{e}_c pour former l'empreinte digitale de la mesure. La dernière étape consiste à déterminer l'empreinte digitale $\mathbf{e}(x, y)$ la plus proche de l'empreinte de mesure \mathbf{e}_c , par un simple calcul de l'erreur quadratique entre l'empreinte digitale $\mathbf{e}(x, y)$ et l'empreinte mesurée \mathbf{e}_c :

$$(\hat{x}, \hat{y}) = \underset{x,y}{\operatorname{argmax}} \left(\|\mathbf{e}(x, y) - \mathbf{e}_c\|^2 \right). \quad (2.4)$$

Nous déduisons alors la position estimée de la cible à partir de l’empreinte trouvée.

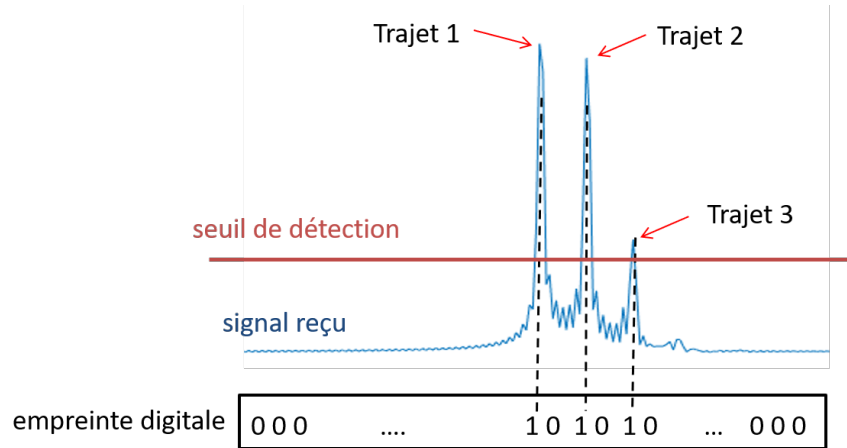


FIGURE 2.3.2 – Exemple de la construction d’une empreinte digitale.

Remarquons finalement que cette méthode est conçue pour le problème de localisation, et non destinée au problème de détection.

2.3.3 Filtre adapté multi-trajets (FMU)

Nous présentons dans cette section la méthode que nous avons développée pour résoudre le problème de détection et localisation dans le contexte du radar around-the-corner. Suivant l’approche DPD (Direct Position Determination) [Weiss 11], nous allons travailler dans l’espace cible (x, y) directement. C’est en effet une méthode optimale comparativement à l’approche classique qui exploite d’abord l’estimation de paramètres intermédiaires pour en déduire ensuite la position.

Pour une position connue (x, y) , le test d’hypothèses pour la détection d’une cible en NLOS peut s’écrire sous la forme :

$$\begin{cases} H_0 : \mathbf{z} = \mathbf{n}, & \text{bruit,} \\ H_1 : \mathbf{z} = \mathbf{R}(x, y)\boldsymbol{\alpha} + \mathbf{n}, & \text{cible+bruit.} \end{cases} \quad (2.5)$$

L’exploitation préalable d’informations sur les amplitudes des trajets $\boldsymbol{\alpha}$ n’est généralement pas facile, car cela nécessiterait une bonne connaissance des matériaux des murs et de leurs réflectivités, ainsi que la bonne connaissance de la SER (Surface Équivalent Radar) de la cible pour tous les angles de présentation. Nous supposons plutôt ici que ces amplitudes sont inconnues et déterministes. La seule connaissance que nous extrayons du modèle de propagation est donc l’information sur les retards des trajets. Classiquement, dans

un tel contexte et selon la stratégie du test du rapport de vraisemblance généralisé (GLRT), les paramètres inconnus sont estimés au sens du maximum de vraisemblance (MV) et réinjectés dans le rapport de vraisemblance du test d'hypothèses (2.5).

La vraisemblance des mesures sous l'hypothèse H_1 est donnée par :

$$p(\mathbf{z}|H_1) \propto \exp\left(-\frac{(\mathbf{z} - \mathbf{R}(x, y)\boldsymbol{\alpha})^H (\mathbf{z} - \mathbf{R}(x, y)\boldsymbol{\alpha})}{\sigma^2}\right), \quad (2.6)$$

où nous supposons la variance σ^2 du bruit connue.

La maximisation de cette vraisemblance par rapport au vecteur d'amplitude $\boldsymbol{\alpha}$ donne l'estimateur suivant :

$$\hat{\boldsymbol{\alpha}} = (\mathbf{R}^H(x, y)\mathbf{R}(x, y))^{-1}\mathbf{R}^H(x, y)\mathbf{z}. \quad (2.7)$$

Si les trajets sont décorrelés $\mathbf{r}^H(t - \tau_i)\mathbf{r}(t - \tau_j) \approx 0$ ($i \neq j$), la matrice $\mathbf{R}^H(x, y)\mathbf{R}(x, y)$ est bien inversible. Dans le cas contraire, cette inversion peut être calculée par la pseudo inverse de Penrose. L'injection de cette expression dans la vraisemblance $p(\mathbf{z}|H_1)$ fournit :

$$p(\mathbf{z}|H_1) \propto \exp\left(\frac{-\mathbf{z}^H\mathbf{z} + \mathbf{z}^H\mathbf{R}(x, y)(\mathbf{R}^H(x, y)\mathbf{R}(x, y))^{-1}\mathbf{R}^H(x, y)\mathbf{z}}{\sigma^2}\right). \quad (2.8)$$

La vraisemblance des mesures sous l'hypothèse H_0 est fournie par :

$$p(\mathbf{z}|H_0) \propto \exp\left(\frac{-\mathbf{z}^H\mathbf{z}}{\sigma^2}\right). \quad (2.9)$$

Le logarithme du rapport de vraisemblance s'exprime donc par :

$$\log \frac{p(\mathbf{z}|H_1)}{p(\mathbf{z}|H_0)} \propto \mathbf{z}^H\mathbf{R}(x, y)(\mathbf{R}^H(x, y)\mathbf{R}(x, y))^{-1}\mathbf{R}^H(x, y)\mathbf{z}, \quad (2.10)$$

quantité à comparer avec un certain seuil de détection.

Le test GLRT pour le problème de détection est alors fourni par :

$$T_{FMU}(x, y) \underset{H_0}{\overset{H_1}{\geq}} \lambda_{FMU}, \quad (2.11)$$

où

$$T_{FMU}(x, y) = \|\mathbf{P}(x, y)\mathbf{z}\|^2, \quad (2.12)$$

avec

$$\mathbf{P}(x, y) = \mathbf{R}(x, y)(\mathbf{R}^H(x, y)\mathbf{R}(x, y))^{-1}\mathbf{R}^H(x, y), \quad (2.13)$$

qui est la matrice de projection sur le sous-espace engendré par les colonnes de la matrice $\mathbf{R}(x, y)$.

Pour une position fixe (x, y) connue, cette solution GLRT est connue comme le détecteur adapté sous-espace [Scharf 94]. Il vise à détecter les signaux appartenant au sous-espace engendré par la matrice $\mathbf{R}(x, y)$, et mesure pour cela l'énergie du signal contenue dans ce sous-espace pour la comparer à un seuil de détection.

Sous l'hypothèse H_0 , la distribution de la variable aléatoire

$$T'_{FMU}(x, y) = \frac{T_{FMU}(x, y)}{\sigma^2/2} \quad (2.14)$$

est une distribution du χ^2 centrée avec $2M(x, y)$ degrés de liberté. Ainsi le seuil λ_{FMU} peut être calculé en fonction du nombre de multi-trajets $M(x, y)$, la variance du bruit σ^2 et la probabilité de fausse alarme P_{FA} [Scharf 94] :

$$\lambda_{FMU} = \sigma^2 \gamma^{-1}(M(x, y), \Gamma(M(x, y))(1 - P_{FA})), \quad (2.15)$$

où $\Gamma(N)$ et $\gamma(N, x)$ sont les fonctions gamma et gamma incomplètes inférieures respectivement :

$$\Gamma(N) = \int_0^{+\infty} e^{-t} t^{N-1} dt, \quad (2.16)$$

$$\gamma(N, x) = \int_0^x t^{N-1} e^{-t} dt. \quad (2.17)$$

La probabilité de détection est fournie par :

$$P_{d(FMU)} = Q_{M(x,y)} \left(\frac{\|\mathbf{R}(x, y)\boldsymbol{\alpha}\|}{\sigma}, \frac{\sqrt{\lambda_{FMU}}}{\sigma} \right), \quad (2.18)$$

où $Q_M(a, b)$ est la fonction Q de Marcum . Elle est définie par [Shnidman 89] :

$$Q_M(a, b) = \int_b^\infty x \left(\frac{x}{a}\right)^{M-1} \exp\left(-\frac{x^2 + a^2}{2}\right) I_{M-1}(ax) dx, \quad (2.19)$$

où $I_M(z)$ est la fonction de Bessel modifiée d'ordre M . Le calcul détaillé du seuil λ_{FMU} et de la probabilité de détection $P_{d(FMU)}$ est présenté en annexe A.

Pour le problème de la localisation, toujours en considérant que $\boldsymbol{\alpha}$ est un vecteur déterministe inconnu, l'estimateur au sens du maximum de vraisemblance de la position (x, y) dans (2.3) est donné par le maximum de $T_{FMU}(x, y)$, dans la mesure où le dénominateur du rapport de vraisemblance $T_{FMU}(x, y)$ ne dépend pas de la position (x, y) (et donc que la maximisation de $p(\mathbf{z}|H_0)$

est équivalente à celle de $T_{FMU}(x, y)$). Comme dans un radar LOS classique, la fonction de coût MV pour une seule cible peut alors être utilisée à la fois pour la détection et la localisation. La valeur $T_{FMU}(x, y)$ (que nous appellerons niveau T-FMU) est calculée pour chaque position (x, y) dans la zone observée. Les cases avec un niveau T élevé sont plus susceptibles de correspondre à la position de la cible. Une estimation de la position cible peut alors être trouvée par :

$$(\hat{x}, \hat{y}) = \underset{x,y}{\operatorname{argmax}}(T_{FMU}(x, y)). \quad (2.20)$$

Afin d'appliquer l'algorithme à notre problème particulier, il est nécessaire d'échantillonner les positions (x, y) . La zone observée pour la détection de la cible est donc divisée en petites cases comme en figure 2.3.3. Une simulation a été réalisée avec un modèle géométrique approximatif d'une intersection urbaine : les portes, fenêtres et autres éléments de rétrodiffusion possibles n'ont pas été modélisés. La propagation du signal est modélisée par un simple tracé de rayons, en supposant que toutes les réflexions sont spéculaires. Les pertes de propagation sont simulées par un modèle simple : la perte est proportionnelle au carré de la distance parcourue par l'onde du radar à la cible et de retour au radar, selon l'équation radar classique [Richards 05]. Pour chaque case (x, y) , une matrice $\mathbf{R}(x, y)$ avec $M(x, y)$ colonnes est construite à partir des retards des multi-trajets τ_k ($k = 1, 2, \dots, M(x, y)$) calculés par le tracé de rayons, où $M(x, y)$ est le nombre de multi-trajets pour cette case. Bien que de nombreux multi-trajets puissent être simulés avec un grand nombre de réflexions, il est possible de ne considérer qu'un nombre réduit de trajets pour l'algorithme de détection-localisation, en supposant que les trajets présentant trop de réflexions seront trop faibles pour fournir des informations exploitables.

Notons que le choix de $M(x, y)$ influence la performance de détection puisque le seuil λ_{FMU} et la matrice $\mathbf{R}(x, y)$ changent lorsque $M(x, y)$ varie.




FIGURE 2.3.3 – Scénario d'une intersection urbaine typiquement considérée.

Nous remarquons qu'un test similaire dans sa structure a été proposé dans [Korkmaz 08] mais pour une application différente dans le but de détecter les multi-trajets puis d'estimer le premier trajet sans chercher à localiser la cible.

2.3.4 Square law combiner (SLC)

Comme décrit ci-dessus, le filtre adapté multi-trajets nécessite de la mémoire pour empiler les paramètres obtenus à partir du modèle de tracé de rayons et/ou le calcul d'une matrice inverse pour chaque position testée. Le temps de calcul et l'espace mémoire peuvent augmenter considérablement lorsque le nombre de positions testées est important. Nous proposons un second algorithme qui permet de réduire ces deux facteurs. Au lieu de projeter le signal reçu sur le sous-espace défini par $\mathbf{R}(x, y)$, cet algorithme calcule l'intégration incohérente de la sortie du filtre adapté pour les retards des multi-trajets fournis par le modèle de propagation. En tant que tel, il partage certaines similitudes avec la technique « square law combiner » considérée dans les transmissions radio [John 02].

Le test de détection de l'algorithme SLC peut alors s'écrire :

$$T_{SLC}(x, y) = \sum_{i \in \Omega(x, y)} |z(i)|^2 \underset{H_0}{\overset{H_1}{\geq}} \lambda_{SLC}, \quad (2.21)$$

où $\Omega(x, y)$ contient l'indice du vecteur \mathbf{z} correspondant aux retards des multi-trajets $\tau_k(x, y)$ obtenus par le modèle de tracé de rayons. Le nombre d'éléments dans $\Omega(x, y)$ est alors égal à $M(x, y)$.

Nous pouvons facilement montrer que la loi de probabilité de la variable aléatoire

$$T'_{SLC}(x, y) = \frac{T_{SLC}(x, y)}{\sigma^2/2} \quad (2.22)$$

sous l'hypothèse H_0 est une distribution du χ^2 centrée avec $2M(x, y)$ degrés de liberté. Ainsi le niveau de seuil λ_{SLC} peut être calculé exactement comme pour l'algorithme FMU précédemment :

$$\lambda_{SLC} = \sigma^2 \gamma^{-1}(M(x, y), \Gamma(M(x, y))(1 - P_{FA})) = \lambda_{MPF}. \quad (2.23)$$

La probabilité de détection est dans ce cas fournie par :

$$P_{d(SLC)} = Q_{M(x, y)} \left(\frac{\sqrt{\sum_{i \in \Omega(x, y)} |[\mathbf{R}(x, y)\boldsymbol{\alpha}]_i|^2}}{\sigma}, \frac{\sqrt{\lambda_{SLC}}}{\sigma} \right), \quad (2.24)$$

où $[\mathbf{R}(x, y)\boldsymbol{\alpha}]_i$ est le i -ème élément du vecteur $\mathbf{R}(x, y)\boldsymbol{\alpha}$. Le calcul détaillé du seuil λ_{SLC} et de la probabilité de détection $P_{d(SLC)}$ se trouve dans l'annexe A.

Comme dans l'algorithme FMU, la valeur $T_{SLC}(x, y)$ (appelée niveau T-SLC) pour le test de détection dans la zone observée peut être calculée pour chaque position (x, y) . Les cases ayant un niveau T-SLC élevé sont plus susceptibles de correspondre à la position de la cible et la position de la cible est estimée comme suit :

$$(\hat{x}, \hat{y}) = \underset{x, y}{\operatorname{argmax}}(T_{SLC}(x, y)). \quad (2.25)$$

2.3.5 Comparaison du FMU et du SLC

Nous présentons dans cette section une brève comparaison entre les détecteurs FMU et SLC proposés, d'une part en terme des performances de détection théorique, et d'autre part en terme de coût de calcul.

2.3.5.1 Comparaison des performances de détection

Il apparaît que l'expression de $P_{d(SLC)}$ ne diffère de l'expression de $P_{d(FMU)}$ que par la valeur du paramètre de non-centralité qui vaut $\frac{\|\mathbf{R}(x, y)\boldsymbol{\alpha}\|}{\sigma}$ pour le FMU et $\frac{\sqrt{\sum_{i \in \Omega(x, y)} |[\mathbf{R}(x, y)\boldsymbol{\alpha}]_i|^2}}{\sigma}$ pour le SLC. Or il est clair que $\|\mathbf{R}(x, y)\boldsymbol{\alpha}\|$ est toujours plus grand que $\sqrt{\sum_{i \in \Omega(x, y)} |[\mathbf{R}(x, y)\boldsymbol{\alpha}]_i|^2}$ puisque $\|\mathbf{R}(x, y)\boldsymbol{\alpha}\| = \sqrt{\sum_i |[\mathbf{R}(x, y)\boldsymbol{\alpha}]_i|^2}$. Comme la fonction Q de Marcum est croissante par rapport à son premier paramètre [Gil 14], il vient donc tout de suite que $P_{d(FMU)} > P_{d(SLC)}$ pour une même probabilité de fausse alarme P_{FA} et un même nombre de trajets $M(x, y)$. Par conséquent, cela prouve que la performance de détection du détecteur FMU est toujours meilleure que celle du détecteur SLC.

2.3.5.2 Comparaison du temps de calcul et de la mémoire

L'algorithme FMU nécessite le calcul des matrices $\mathbf{P}(x, y)$ pour chaque position (x, y) . Ces matrices sont fournies par le modèle de propagation fondé sur une méthode de tracé de rayons. L'exécution du modèle de propagation pour chaque position à chaque itération peut être très coûteuse. Cependant, l'algorithme FMU peut être implémenté de différentes manières. Afin de diminuer le temps de calcul, une première possibilité peut être de stocker les matrices $\mathbf{P}(x, y)$ (de taille $N \times N$) fournies par l'équation (2.13) pour toutes les cases de la zone observée. Cela permet d'éviter le calcul des inverses de matrices, ce qui

réduit le coût en temps mais augmente les besoins en mémoire. Une autre implémentation peut être de stocker les matrices $\mathbf{R}(x, y)$ (de taille $N \times M(x, y)$) pour toutes les cases et de calculer $\mathbf{P}(x, y)$ à chaque lancement de programme. Cette implémentation diminue ainsi l'exigence de mémoire en augmentant le temps de calcul. La troisième possibilité est de stocker seulement les paramètres des matrices \mathbf{R} (retards $\tau_k(x, y)$) et le signal d'autocorrélation $r(t)$, puis de construire \mathbf{R} et de calculer \mathbf{P} à chaque lancement de programme. Un exemple de comparaison des exigences de mémoire et de temps de calcul de l'algorithme SLC d'une part et les trois types d'implémentation pour l'algorithme FMU, d'autre part, est présenté dans le Tableau 2.1.

	Time (s)	Memory (MB)
SLC	0.02	0.04
FMU : stacking \mathbf{P}	0.20	2145
FMU : stacking \mathbf{R}	0.92	22
FMU : stacking parameters of \mathbf{R}	1.27	0.04

TABLE 2.1 – Comparaison de la mémoire nécessaire et du temps de calcul pour l'algorithme SLC et les trois implémentations possibles de l'algorithme FMU. $N = 300$, $M(x, y) = 3$, zone d'intérêt avec 40x40 cases. Environnement Matlab, PC 2.8 GHz.

Il ressort de cette comparaison que l'algorithme SLC fournit un gain important aussi bien en temps de calcul qu'en mémoire. Selon la méthode d'implémentation considérée, l'algorithme FMU peut être rapide mais gourmand en mémoire, ou vice versa.

2.4 Sélection du nombre de trajets pris en compte

Comme remarqué dans la section précédente, le choix du nombre de trajets pris en compte influence les performances de détection des algorithmes FMU et SLC. Dans cette section, nous allons d'abord montrer que la prise en compte des trajets supplémentaires peut améliorer les performances de détection. Ensuite, nous proposerons une méthode originale pour sélectionner le nombre optimal de trajets en fonction d'un critère de performance de détection. L'algorithme de détection suivant est développé avec l'algorithme FMU en raison de ses meilleures performances de détection par rapport à l'algorithme SLC.

2.4.1 Comparaison des performances de détection : N vs $N + 1$ trajets

Dans cette section, l'objectif est de comparer les performances de détection de l'algorithme FMU avec N et $N + 1$ multi-trajets respectivement. Nous montrerons que la prise en compte d'un trajet supplémentaire dans le processus de détection peut augmenter la performance de détection si l'énergie du trajet supplémentaire est suffisante.

Sans perte de généralité, nous supposons que $\|\mathbf{r}\| = 1$ et $\sigma_n^2 = 1$ de sorte que chaque α_i représente le rapport signal sur bruit (SNR) du i -ième trajet respectivement. Nous supposons par souci de simplicité et sans perte de généralité que $|\alpha_1| \geq |\alpha_2| \geq \dots \geq |\alpha_n| \geq |\alpha_{n+1}|$. Nous définissons $\boldsymbol{\alpha}_{1:n} = [\alpha_1, \alpha_2, \dots, \alpha_n]$.

Nous supposons également que $\mathbf{r}(t - \tau_i)$ et $\mathbf{r}(t - \tau_j)$ sont non-corrélés pour toutes les paires (i, j) , c'est-à-dire $\mathbf{r}^H(t - \tau_i)\mathbf{r}(t - \tau_j) \approx 0$, ce qui est approximativement le cas lorsque les deux trajets considérés ne sont pas trop proches. Ou, pour être plus précis, quand $|\tau_i - \tau_j|$ est plus grand que $1/B$. La probabilité de détection de l'algorithme FMU avec n multi-trajets est alors :

$$P_d^{(n)}(\boldsymbol{\alpha}_{1:n}) = Q_n \left(\sqrt{2 \sum_{k=1}^n |\alpha_k|^2}, \sqrt{2t_n} \right), \quad (2.1)$$

où $t_n = \gamma^{-1}(n, \Gamma(n)(1 - P_{fa}))$ est le seuil de détection pour n trajets.

De même, la probabilité de détection de l'algorithme FMU avec $n + 1$ multi-trajets est :

$$P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) = Q_{n+1} \left(\sqrt{2 \sum_{k=1}^{n+1} |\alpha_k|^2}, \sqrt{2t_{n+1}} \right) \quad (2.2)$$

où $t_{n+1} = \gamma^{-1}(n + 1, \Gamma(n + 1)(1 - P_{fa}))$ est le seuil de détection pour $n + 1$ trajets.

Ici, nous voulons déterminer quel nombre de trajets fournit la meilleure probabilité de détection P_d , et pour quel ensemble de paramètres. Cela conduit à comparer les deux quantités $P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ et $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1})$ pour différentes valeurs de α_k , c'est-à-dire, à comparer deux fonctions Q de Marcum $Q_M(a, b)$ avec trois paramètres différents M , a et b . Or $Q_M(a, b)$ est croissante avec M et a mais décroissante avec b [Gil 14]. Par conséquent, il n'est pas trivial de comparer $P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ et $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1})$. À notre connaissance, cette comparaison complexe n'a pas encore été étudiée dans la littérature.

La figure 2.4.1 montre quelques exemples de la variation de $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) - P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ en fonction de $|\alpha_{n+1}|$ pour certaines valeurs spécifiées de n et $\boldsymbol{\alpha}_{1:n}$. Nous observons qu'il y a toujours une et une seule intersection entre les courbes




FIGURE 2.4.1 – $P_d^{(n+1)}(\alpha_{1:n+1}) - P_d^{(n)}(\alpha_{1:n})$ pour différentes valeurs de n et différents SNR de trajets.

$P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) - P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ et l'axe horizontal zéro. De nombreuses autres simulations numériques pour d'autres valeurs de $\boldsymbol{\alpha}_{1:n}$ et de plus grandes valeurs de n permettent de conclure qu'il semble qu'il existe toujours $\alpha' < |\alpha_n|$, tel que pour $\alpha' < |\alpha_{n+1}| \leq |\alpha_n|$, nous avons $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) > P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ et pour $|\alpha_{n+1}| < \alpha'$, $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) < P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$. Cela signifie que tant que le SNR du $n + 1$ ème trajet reste suffisamment important, alors la prise en compte de ce trajet dans le test de détection permet d'améliorer la probabilité de détection. Au contraire, si ce SNR est insuffisant, il n'est pas intéressant de considérer ce trajet supplémentaire car la performance de détection n'en sera pas améliorée, et pourra même être dégradée.

Proposition 1. *Il existe toujours $\alpha' < |\alpha_n|$, tel que pour $\alpha' < |\alpha_{n+1}| \leq |\alpha_n|$, nous avons $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) > P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ et pour $|\alpha_{n+1}| < \alpha'$, $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) < P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$.*

Démonstration. Une preuve analytique asymptotique (à fort SNR) de cette conclusion se trouve dans l'annexe B. \square

Ce résultat implique qu'il peut être intéressant de considérer plusieurs trajets dans le test de détection afin d'améliorer les performances de détection, et pose ainsi la question du choix du nombre optimal de trajets à considérer pour obtenir la meilleure probabilité de détection. Nous allons aborder ce problème dans la section suivante.

2.4.2 Algorithme de sélection du nombre de trajets

Afin d'examiner la variation de la probabilité de détection par rapport au nombre de trajets, nous allons tout d'abord considérer un modèle simple d'atténuation : nous supposons que $\alpha_k = \gamma^{k-1}\alpha_1$ ($\gamma < 1$). Cela signifie que le SNR du k -ème trajet est plus petit que celui du $(k-1)$ ème trajet d'une certaine valeur en dB constante (en fonction d'une valeur prédéfinie γ). La figure 2.4.2 illustre la variation de la probabilité de détection $P_d^{(n)}$ en fonction du nombre de trajets pris en compte. Différentes valeurs de γ (perte par trajet) et α_1 (amplitude du premier trajet) sont choisies.

A partir de la figure 2.4.2, nous pouvons observer que pour toutes les cases considérées, il existe en effet une valeur optimale de M qui maximise $P_d^{(M)}$. Ceci peut être expliqué facilement : l'ajout d'un trajet permet de récupérer plus d'énergie de la cible mais augmente également l'énergie du bruit recueillie puisque nous augmentons la dimension du sous-espace signal. Tant que le SNR du trajet additionnel reste suffisamment fort pour combattre cette augmentation du bruit, la performance de détection sera améliorée. Ce nombre optimal dépend du SNR du premier trajet et du schéma de perte particulier.




FIGURE 2.4.2 – P_d en fonction du nombre de multi-trajets pour différents SNRs du premier trajet. Les croix rouges représentent le maximum de P_d pour chaque courbe.

Cependant, en réalité, les SNRs des différents multi-trajets ne diminuent pas selon le schéma simple décrit ci-dessus. En effet, la perte des trajets dépend de la géométrie de la scène, des coefficients de réflexion des surfaces environnantes et de la cible, ainsi que de la position et de l'orientation de la cible. Le nombre optimal de trajets à prendre en compte est donc difficile à évaluer sans a priori fait sur la scène et les conditions de propagation. Nous proposons donc un algorithme de sélection pour sélectionner le nombre de trajets pour l'algorithme de détection à partir des données mesurées, sans nécessiter l'exploitation de tels a priori.

Le critère que nous retenons pour cette estimation du nombre de trajets est la probabilité de détection pour une probabilité de fausse alarme fixée. La recherche du nombre optimal de trajets conduit à résoudre le problème d'optimisation suivant :

$$M_{opt} = \underset{M}{\operatorname{argmax}} P_d^{(M)}(\boldsymbol{\alpha}_{1:M}), \quad (2.3)$$

avec

$$P_d^{(M)}(\boldsymbol{\alpha}_{1:M}) = Q_M \left(\sqrt{2 \left(\sum_{k=1}^M |\alpha_k|^2 \right)}, \sqrt{2t_M} \right), \quad (2.4)$$

où $|\alpha_1| \geq |\alpha_2| \geq \dots \geq |\alpha_M|$, $t_M = \gamma^{-1}(M, \Gamma(M)(1 - P_{fa}))$ en supposant que $\mathbf{r}(\tau_i)$ et $\mathbf{r}(\tau_j)$ sont non-corrélés pour toutes les paires (i, j) .

L'idée majeure ici est que seuls les trajets qui contribuent positivement à augmenter P_d doivent être pris en compte. En condition réelle, les SNRs des

différents trajets ne sont pas connus et doivent être estimés à partir d'un signal bruité. L'estimation au sens du maximum de vraisemblance des amplitudes α_k donnée par l'équation (2.7) peut être utilisée pour estimer M_{opt} :

$$\hat{M}_{opt} = \underset{M}{\operatorname{argmax}} P_d^{(M)}(\hat{\boldsymbol{\alpha}}_{1:M}). \quad (2.5)$$

Nous proposons alors l'algorithme de sélection suivant pour choisir le nombre optimal M pour maximiser la performance de détection : l'algorithme consiste à estimer dans un premier temps le vecteur d'amplitudes $\hat{\boldsymbol{\alpha}}$ pour un nombre maximum M_{max} de trajets fixé au préalable. Une fois ces amplitudes estimées, nous les trions par ordre décroissant d'énergie. Nous calculons alors la probabilité de détection $P_d^{(M)}$ pour différentes valeurs de $M = 1, 2, \dots, M_{max}$ en utilisant les M premières valeurs d'amplitude. La valeur de M qui fournit la probabilité de détection maximale est alors conservée pour l'application de l'algorithme de détection. Cet algorithme de sélection du nombre de trajets est résumé par l'algorithme 1. A noter que cette recherche de M_{opt} doit être effectuée pour chaque case (x, y) .

Algorithme 1 : Sélection du nombre de trajets pris en comptes

- 1 Étape 1 : Estimer $\hat{\boldsymbol{\alpha}}$ à partir du signal mesuré
 - 2 Étape 2 : Trier les $\hat{\alpha}_k$ par ordre décroissant ($|\hat{\alpha}_1| \geq |\hat{\alpha}_2| \geq \dots \geq |\hat{\alpha}_{M_{max}}|$)
 - 3 Étape 3 : Calculer $P_d^{(M)}$ pour différentes valeurs de $M \in \{1, \dots, M_{max}\}$
 - 4 Étape 4 : Chercher la valeur optimale de M (\hat{M}_{opt}) qui maximise $P_d^{(M)}$
-

2.5 Simulations et résultats

2.5.1 Description des simulations

Afin d'évaluer les algorithmes de détection et localisation proposés et l'algorithme de sélection du nombre de trajets, nous effectuons des simulations en considérant un modèle simple d'intersection urbaine présenté en figure 2.5.1. La zone observée est discrétisée par des cases de taille 0,25 m x 0,25 m. Un radar est placé aux coordonnées (0; 2) et émet un signal de fréquence centrale 3 GHz. Le signal transmis consiste en un train cohérent d'impulsions modulées linéairement en fréquence (signal « chirp »). La bande passante choisie vaut 300 MHz, ce qui correspond à une résolution distance de 0,5 m. Une largeur de bande assez importante est en effet nécessaire pour pouvoir distinguer les multi-trajets proches. Les pertes de propagation sont simulées par un

modèle simple : la perte est proportionnelle au carré de la distance parcourue par l'onde du radar à la cible et de retour au radar, selon l'équation radar classique [Richards 05]. Des pertes par réflexion sont également ajoutées de manière simple à raison d'une perte constante de 3 dB par réflexion.





FIGURE 2.5.1 – Scénario d'intersection urbaine simulé pour les mesures de performances.

2.5.2 Sélection du nombre de trajets

Dans un premier temps, il est souhaitable de déterminer le nombre optimal de multi-trajets pour toutes les positions de la zone observée dans le scénario simulé. En appliquant l'algorithme de sélection du nombre de trajets décrit ci-dessus, la carte du nombre optimal pour toutes les positions de la cible est montrée en figure 2.5.2a. Nous pouvons observer que M_{opt} est principalement contenu dans l'intervalle de 2 à 4 avec le schéma de perte considéré pour la simulation. Toutefois pour certaines positions, M_{opt} est relativement important en raison des fortes amplitudes de multi-trajets dues au choix du modèle d'amplitude et à la géométrie de la scène. Ces résultats sont comparés avec la carte théorique en figure 2.5.2b qui fournit le nombre de trajets optimal dans la même configuration mais sans bruit. Nous observons effectivement une similarité entre deux cartes. Nous constatons que l'algorithme estime bien le nombre de trajets pouvant être pris en compte en présence du bruit.

2.5.3 Comparaison des performances de détection

Afin d'évaluer les performances des algorithmes FMU et SLC pour une cible localisée en NLOS, il est nécessaire de définir le SNR afin de prendre en compte les pertes des multi-trajets. Pour cela, définissons d'abord pour chaque trajet



(a) Carte fournie par l'algorithme de sélection du nombre de trajets. Simulation réalisée avec un modèle approximatif d'une intersection urbaine décrite dans la section 2.5.1 avec SNR = 15 dB.

(b) Carte théorique. Même configuration mais sans bruit.

FIGURE 2.5.2 – Carte du nombre optimal de multi-trajets trouvée par l'algorithme de sélection du nombre de trajets comparée avec la carte théorique.

i la perte de propagation (incluant la perte de réflexion) ν_i ($\nu_i \leq 1$) et l'amplitude de la cible κ telle que $\alpha_i = \nu_i \kappa$ (nous supposons ici que l'amplitude de la cible est identique pour toutes les directions de trajet (pas de fluctuation de SER)). Le rapport signal sur bruit (SNR - Signal to Noise Ratio en anglais) est alors :

$$\begin{aligned} \text{SNR} &= \frac{\|\mathbf{R}(x, y)\boldsymbol{\alpha}\|^2}{\sigma^2} \\ &\approx \frac{\|\boldsymbol{\alpha}\|^2}{\sigma^2} = \frac{\left(\sum_i |\nu_i|^2\right) \kappa^2}{\sigma^2}, \end{aligned} \quad (2.1)$$

en supposant que les retards des multi-trajets sont résolus.

La figure 2.5.3 fournit les probabilités de détection lorsque la cible est située à la position de référence (39, 875; 10, 125) qui correspond à une position en ligne de vue du radar (LOS). Comme la perte $\sum_i |\nu_i|^2$ est constante dans notre simulation pour une position fixe, la variation de SNR de la cible est obtenue en faisant varier la valeur de κ . Les probabilités de détection pour les algorithmes FMU et SLC sont obtenues par simulation de Monte Carlo et comparées aux formules théoriques fournies par les équations (2.18) et (2.24). La probabilité de détection du filtre adapté classique pour un seul trajet est également esti-

mée par simulation de Monte Carlo en considérant le trajet le plus fort, ainsi que la performance de détection du filtre adapté clairvoyant pour lequel les paramètres du signal reçu sont parfaitement connus (c'est-à-dire les amplitudes et phases sont parfaitement connues, ce qui est bien entendu irréaliste). Remarquons ici que les performances de détection de l'algorithme d'empreintes digitales correspondent à celles du filtre adapté mono-trajet, puisque le seuil de détection considéré pour la méthode des empreintes digitales est effectivement celui du filtre adapté classique mono-trajet. Sur cette position en LOS, la performance du FMU est toujours meilleure que la performance du filtre adapté n'exploitant qu'un seul trajet pour chaque SNR. La courbe de performance du SLC est très proche de celle du FMU. Nous pouvons observer une perte de 2 dB entre les détecteurs FMU / SLC et le filtre adapté clairvoyant. Cette perte résulte de la méconnaissance des amplitudes des trajets qui nous imposent, dans le cas du FMU, de projeter le signal reçu sur un sous-espace de dimension M plutôt que de faire un filtre adapté classique avec le signal idéal composite, et dans le cas du SLC de l'intégration incohérente des trajets. Nous observons par ailleurs la bonne concordance entre les probabilités de détection théoriques des deux détecteurs proposés, et les performances obtenues par Monte Carlo.




FIGURE 2.5.3 – Probabilité de détection en fonction du SNR. Cible localisée à la position de référence $(39, 875; 10, 125)$. $M_{opt} = 2$ pour les algorithmes FMU et SLC. $P_{fa} = 10^{-3}$. Pertes $\sum_i |\nu_i|^2 = 7.12$ dB.

Nous présentons en figure 2.5.4 les mêmes courbes pour une cible en NLOS située aux coordonnées $(35, 125; 12, 125)$. Il est d'abord noté que toutes les courbes sont décalées vers des valeurs plus élevées de κ , ce qui signifie qu'en

raison de la perte de propagation, un niveau plus élevé d'amplitude de la cible est nécessaire pour la détection. Nous observons toujours que les algorithmes FMU et SLC offrent une meilleure performance de détection par rapport au filtre adapté classique n'exploitant qu'un seul trajet : l'exploitation de plusieurs trajets permet donc bien dans ce cas de figure d'améliorer les performances de détection de la cible. En particulier, le gain apporté par le détecteur FMU par rapport au détecteur filtre adapté mono-trajet vaut environ 4,5 dB pour une probabilité de détection de 0,9. Cependant, cette fois, nous pouvons observer une dégradation de 1,5 dB des performances du détecteur SLC par rapport à celles du détecteur FMU, ce qui est cohérent avec la démonstration théorique de la section 2.3.5. En fonction des performances demandées, cette dégradation peut être acceptée pour accélérer le temps de calcul et la charge mémoire.




FIGURE 2.5.4 – Probabilité de détection en fonction du SNR. Cible localisée à la position $(35, 125; 12, 125)$. $M_{opt} = 3$ pour les algorithmes FMU et SLC. $P_{fa} = 10^{-3}$. Pertes $\sum_i |\nu_i|^2 = 15.91$ dB.

2.5.4 Résultats de localisation sur signaux simulés

Pour examiner la performance de localisation des méthodes proposées, nous considérons deux simulations avec une cible se situant aux deux positions NLOS $(32; 14, 25)$ et $(37; 14, 25)$. Les figures 2.5.5a et b montrent les résultats de la méthode d'empreintes digitales par rapport aux coordonnées x et y . Nous observons que dans les deux cas, l'un des maxima des plots tombe bien à la position de la cible. Par contre, d'autres positions fournissent des sorties du test de détection de même niveau, que nous appelons « ambiguïtés spatiales totales ». La méthode ne permet pas de distinguer la vraie position de la cible et d'autres positions fantômes.

Les résultats de l'algorithme de localisation FMU sont montrés en figure 2.5.5c et d. Les niveaux de couleur représentent la sortie de l'algorithme de localisation FMU, ou niveau T-FMU. Sur les deux figures, nous pouvons voir que le maximum correspond bien à la position réelle de la cible. Les figures 2.5.5e et f présentent les résultats obtenus pour l'algorithme SLC et montrent également que le maximum correspond bien à la position réelle de la cible.

Cependant, la présence de la cible dans la scène a également créé beaucoup d'artéfacts. Dans de nombreuses cases autres que celle de la cible, le niveau T-FMU ou T-SLC fourni par les algorithmes FMU ou SLC est relativement élevé. Ces cases correspondent à des « ambiguïtés spatiales » et peuvent être assimilées à des lobes latéraux élevés du filtre adapté multi-trajets (ou de l'algorithme SLC) proposé. Ceci est dû au fait que, selon la géométrie de la scène, il peut y avoir plusieurs cases dont les retards des multi-trajets sont assez similaires aux retards attendus pour la position réelle de la cible. En particulier, de nombreuses cases différentes peuvent partager au moins un ou deux délais similaires. Nous observons donc que les ambiguïtés de l'algorithme FMU sont très similaires à celles du SLC. Ces ambiguïtés spatiales sont susceptibles de générer des maxima locaux qui non seulement créeront potentiellement une détection fantôme, mais génèreront également un biais important dans la performance de localisation. Ces ambiguïtés, dues à la géométrie de la scène et à la méconnaissance des amplitudes des trajets, sont très difficiles à éviter. Ce phénomène est bien connu dans l'exploitation des multi-trajets pour la localisation [Setlur 14].

Les résultats présentés en figure 2.5.5 sont obtenus pour deux positions de cible uniquement et sans quantification de la performance de localisation. Nous allons maintenant considérer plusieurs positions différentes, correspondant typiquement à une cible se déplaçant dans la zone NLOS, et quantifier la performance de localisation de la cible en fonction de sa position. Pour cela, une cible est simulée, se déplaçant horizontalement de la position (30; 14, 25) à la position (40; 14, 25). Les algorithmes de localisation FMU et SLC sont appliqués pour 40 positions à intervalle constant entre les deux extrémités. Pour chaque position, nous cherchons alors la position cible estimée (\hat{x}, \hat{y}) qui maximise le niveau T pour chaque algorithme. Ensuite, la racine de l'erreur quadratique moyenne (REQM) fournie par :

$$\text{REQM} = \sqrt{\left[\sum_{n=1}^{MC} ((x - \hat{x}_n)^2 + (y - \hat{y}_n)^2) \right] / MC}, \quad (2.2)$$

est calculée à partir de $MC = 1000$ simulations de Monte Carlo et présentée en figure 2.5.6.

Nous pouvons observer un bon accord entre les positions réelles de la cible et

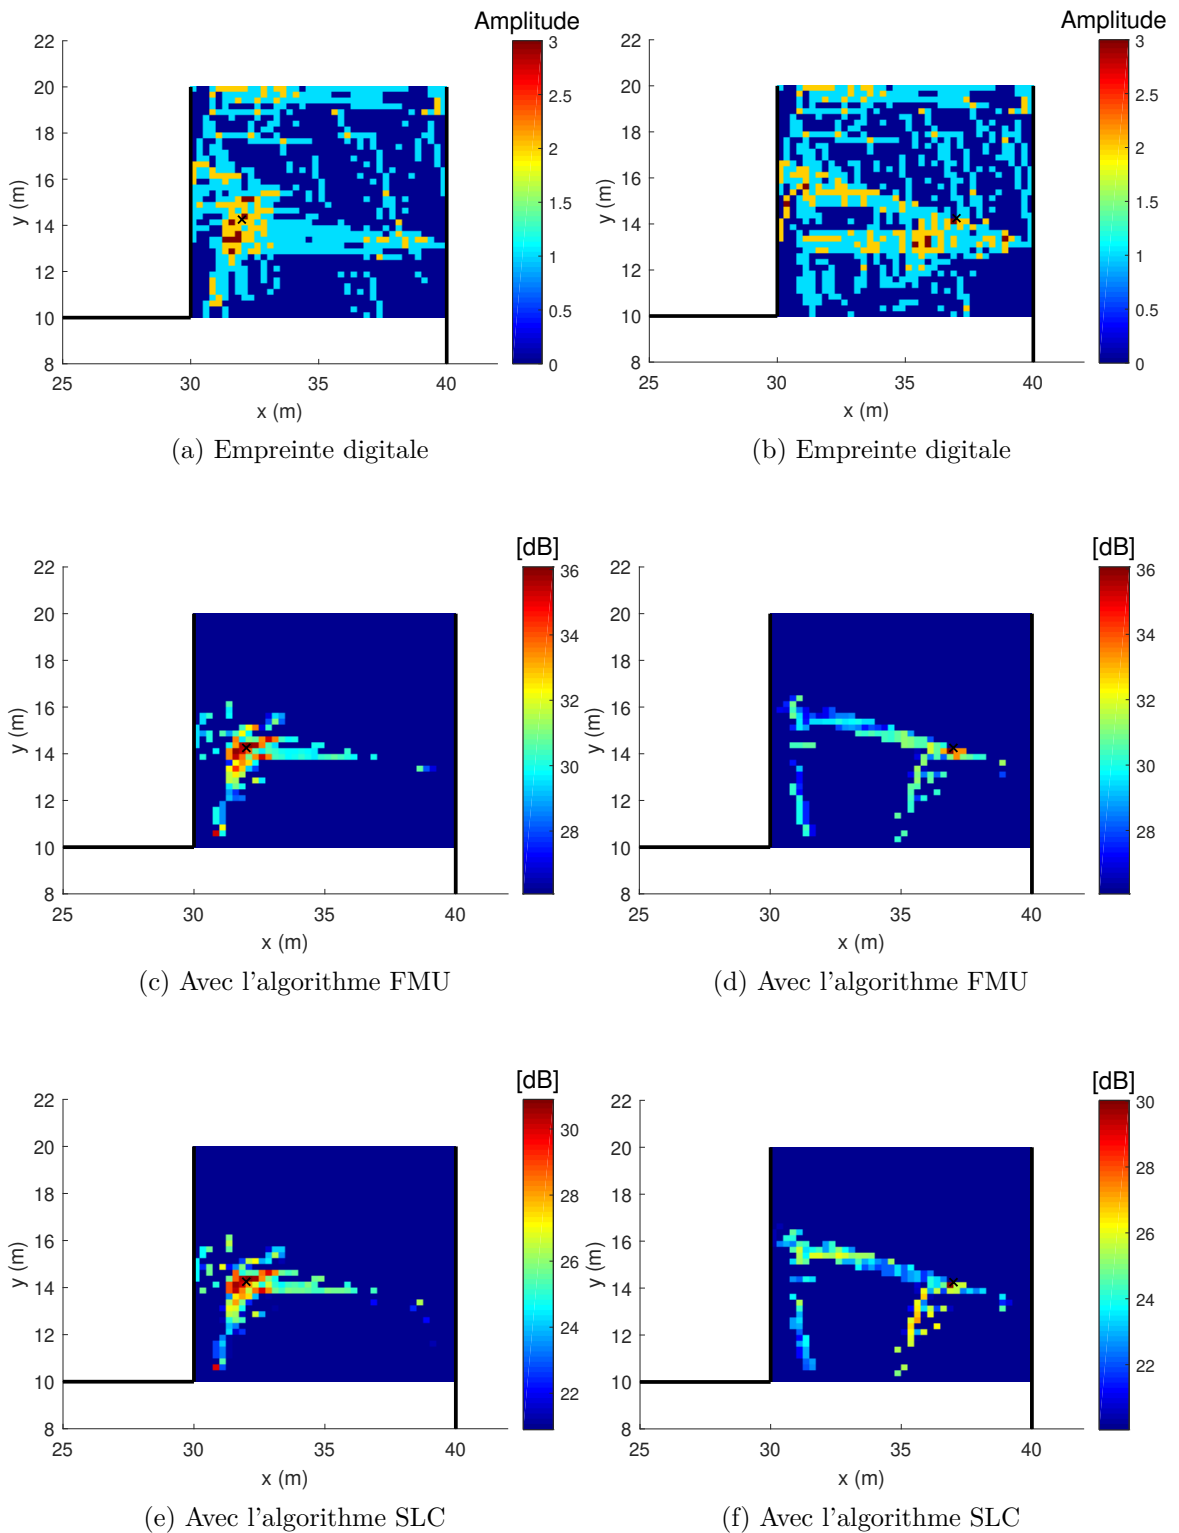


FIGURE 2.5.5 – Résultat de la localisation pour une cible à $(32; 14, 25)$ (gauche) et $(37; 14, 25)$ (droite). La croix noire représente la vraie position de la cible. SNR=15 dB.

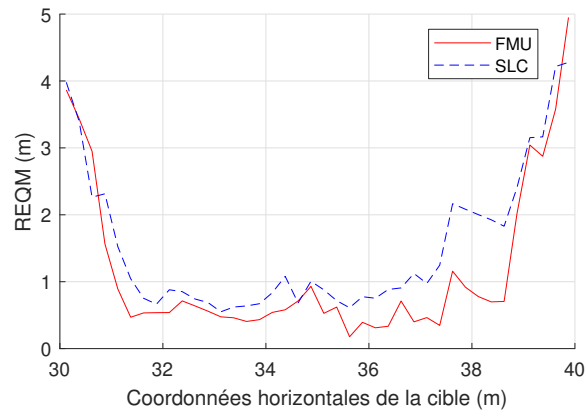


FIGURE 2.5.6 – Erreur de localisation le long de la trajectoire cible. SNR=15dB.

celles estimées sauf aux extrémités de la trajectoire où l'information de multi-trajets n'est pas suffisante pour assurer une bonne localisation (c'est-à-dire l'absence de multi-trajets ou de multi-trajets non résolus). Globalement, la REQM obtenue pour l'algorithme FMU est meilleure que celle obtenue pour l'algorithme SLC.

2.6 Gestion des ambiguïtés

Comme nous l'avons montré dans la section précédente, la cible peut être localisée en exploitant les multi-trajets par les deux méthodes proposées. Par contre, nous avons remarqué que les ambiguïtés spatiales sont souvent fortes et peuvent causer des fausses localisations. Notons également que jusqu'à présent le nombre de trajets pris en compte pour chaque case est le même pour la détection et la localisation. Il est choisi par l'algorithme de sélection du nombre de trajets proposé dans la section 2.4. Or cet algorithme a été développé dans le but de maximiser la probabilité de détection. Toutefois, du point de vue de la localisation, cette façon de choisir le nombre de trajets peut ne pas être très pertinente : une position avec beaucoup de trajets peut être la source d'ambiguïtés de localisation car certains retards de cette position ont plus de chance d'être similaires aux retards des autres positions. Pour limiter l'impact de ce phénomène sur la performance de localisation, nous proposons d'ajouter un terme de pénalisation dans le test de localisation. Par exemple, une position avec plus de trajets est pénalisée avec le terme ajouté. La position de la cible est donc estimée à partir de cette nouvelle quantité combinée de la vraisemblance et du terme de pénalisation. Cette stratégie est similaire à l'ap-

proche de sélection de modèle développée en théorie de l'information. L'idée de base de la sélection de modèle est de chercher un modèle qui représente un bon compromis entre la qualité de l'ajustement et la complexité du modèle. Les modèles plus complexes seront mieux en mesure d'adapter leur forme aux données, mais les paramètres supplémentaires peuvent ne rien représenter d'utile. La qualité d'ajustement du modèle est généralement déterminée en utilisant une approche fondée sur le rapport de vraisemblance alors que la complexité est mesurée par le nombre de paramètres dans le modèle.

Nous présentons ensuite trois améliorations de l'algorithme FMU du point de vue de la localisation en testant différentes pénalisations.

2.6.1 Pénalisation avec critère BIC

Nous considérons ici que chaque case discrétisée de l'espace, centrée en (x_k, y_k) correspond à un certain modèle k . Nous cherchons le modèle le plus approprié pour le signal reçu \mathbf{z} . La case correspondant à ce dernier modèle est a priori la plus probable correspondant à la position de la cible. Les modèles peuvent s'écrire sous la forme :

$$\mathcal{H}_k : \mathbf{z} = \mathbf{R}(x_k, y_k)\boldsymbol{\alpha}_k + \mathbf{n}, \quad (2.1)$$

où le bruit \mathbf{n} est supposé blanc gaussien de variance inconnue σ_k^2 . La matrice \mathbf{R} ainsi que sa taille est différente d'un modèle à l'autre. Le nombre de colonnes de la matrice \mathbf{R} est égal au nombre de trajets pris en compte pour la case (x_k, y_k) . Le nombre de trajets pour chaque case (x_k, y_k) est préalablement fixé par l'algorithme de sélection du nombre de trajets. Les amplitudes $\boldsymbol{\alpha}_k$ sont supposées inconnues et déterministes. Elles peuvent être estimées par l'équation suivante :

$$\hat{\boldsymbol{\alpha}}_k = (\mathbf{R}^H(x_k, y_k)\mathbf{R}(x_k, y_k))^{-1}\mathbf{R}^H(x_k, y_k)\mathbf{z}. \quad (2.2)$$

La variance du bruit σ_k^2 est supposée inconnue et estimée alors par :

$$\hat{\sigma}_k^2 = \frac{(\mathbf{z} - \mathbf{R}(x_k, y_k)\hat{\boldsymbol{\alpha}}_k)^H(\mathbf{z} - \mathbf{R}(x_k, y_k)\hat{\boldsymbol{\alpha}}_k)}{N}. \quad (2.3)$$

Le critère d'information bayésien (BIC) proposé par [Schwarz 78] repose sur un compromis entre la qualité de l'ajustement et la complexité du modèle, en pénalisant les modèles ayant un grand nombre de paramètres, ce qui limite les effets d'« overfitting » (augmenter le nombre de paramètres améliore nécessairement la qualité de l'ajustement). Dans notre application précise, le critère BIC peut être donné par l'équation suivante [Stoica 12] :

$$\text{BIC}(k) = -2 \ln p(\mathbf{z}|\mathcal{H}_k, \hat{\boldsymbol{\alpha}}_k) + \ln \left(\det \left(-\frac{\partial^2 \ln p(\mathbf{z}|\mathcal{H}_k, \boldsymbol{\alpha}_k)}{\partial \boldsymbol{\beta}_k \partial \boldsymbol{\beta}_k^H} \right) \right), \quad (2.4)$$

où $\boldsymbol{\beta}_k = [\boldsymbol{\alpha}_k; \sigma_k^2]$ et $\det(\mathbf{A})$ est le déterminant de la matrice \mathbf{A} .

Sous \mathcal{H}_k , pour calculer le premier terme du critère, nous avons :

$$p(z|\mathcal{H}_k, \hat{\boldsymbol{\alpha}}_k) = \frac{1}{\pi^N \hat{\sigma}_k^{2N}} \exp\left(-\frac{1}{\hat{\sigma}_k^2} (\mathbf{z} - \mathbf{R}(x_k, y_k) \hat{\boldsymbol{\alpha}}_k)^H (\mathbf{z} - \mathbf{R}(x_k, y_k) \hat{\boldsymbol{\alpha}}_k)\right), \quad (2.5)$$

$$= \frac{1}{\pi^N \hat{\sigma}_k^{2N}} \exp\left(-\frac{1}{N}\right), \quad (2.6)$$

en remplaçant $\hat{\sigma}_k^2$ par l'équation (2.3). Pour le second terme, nous avons :

$$\frac{\partial^2 \ln p(\mathbf{z}|\mathcal{H}_k, \boldsymbol{\alpha}_k)}{\partial \boldsymbol{\beta}_k \partial \boldsymbol{\beta}_k^H} = \frac{\partial^2 \left(N \ln \sigma_k^2 + \frac{1}{\sigma_k^2} (\mathbf{z} - \mathbf{R}(x_k, y_k) \boldsymbol{\alpha}_k)^H (\mathbf{z} - \mathbf{R}(x_k, y_k) \boldsymbol{\alpha}_k) \right)}{\partial \boldsymbol{\beta}_k \partial \boldsymbol{\beta}_k^H} \quad (2.7)$$

$$= \begin{bmatrix} \frac{\mathbf{R}^H(x_k, y_k) \mathbf{R}(x_k, y_k)}{\hat{\sigma}_k^2} & \frac{\mathbf{R}^H(x_k, y_k) (\mathbf{z} - \mathbf{R}(x_k, y_k) \hat{\boldsymbol{\alpha}}_k)}{\hat{\sigma}_k^4} \\ \frac{\mathbf{R}^H(x_k, y_k) (\mathbf{z} - \mathbf{R}(x_k, y_k) \hat{\boldsymbol{\alpha}}_k)}{\hat{\sigma}_k^4} & \frac{N}{2\hat{\sigma}_k^4} \end{bmatrix} \quad (2.8)$$

$$= \begin{bmatrix} \frac{1}{\hat{\sigma}_k^2} \mathbf{R}^H(x_k, y_k) \mathbf{R}(x_k, y_k) & 0 \\ 0 & \frac{N}{2\hat{\sigma}_k^4} \end{bmatrix}, \quad (2.9)$$

car

$$\begin{aligned} \mathbf{R}^H(x_k, y_k) (\mathbf{z} - \mathbf{R}(x_k, y_k) \hat{\boldsymbol{\alpha}}_k) &= \mathbf{R}^H(x_k, y_k) \mathbf{z} - \mathbf{R}^H(x_k, y_k) \mathbf{R}(x_k, y_k) \\ &\quad \times \left(\mathbf{R}^H(x_k, y_k) \mathbf{R}(x_k, y_k) \right)^{-1} \mathbf{R}^H(x_k, y_k) \mathbf{z} \\ &= \mathbf{R}^H(x_k, y_k) \mathbf{z} - \mathbf{R}^H(x_k, y_k) \mathbf{z} \quad (2.10) \\ &= 0. \quad (2.11) \end{aligned}$$

Nous déduisons :

$$\text{BIC}(k) = 2N \ln \hat{\sigma}_k^2 + \ln \left(\det \begin{bmatrix} \frac{1}{\hat{\sigma}_k^2} \mathbf{R}^H(x_k, y_k) \mathbf{R}(x_k, y_k) & 0 \\ 0 & \frac{N}{2\hat{\sigma}_k^4} \end{bmatrix} \right). \quad (2.12)$$

En supposant que les multi-trajets ne sont pas corrélés, nous avons

$$\mathbf{R}^H(x_k, y_k) \mathbf{R}(x_k, y_k) = \mathbf{I}_{M_k}, \quad (2.13)$$

où M_k est le nombre de trajets correspondant à la case centrée en (x_k, y_k) . Le critère devient :

$$\text{BIC}(k) \approx 2N \ln \hat{\sigma}_k^2 - (M_k + 2) \ln \hat{\sigma}_k^2. \quad (2.14)$$

Le modèle retenu sera le modèle k_{BIC} qui minimise la valeur BIC :

$$k_{BIC} = \underset{k}{\text{argmin}} \text{BIC}(k). \quad (2.15)$$

La position (x_{BIC}, y_{BIC}) correspondant au modèle k_{BIC} est estimée comme la position de la cible.

2.6.2 Pénalisation avec critère AIC

Une alternative au critère BIC couramment utilisée pour le problème de la sélection de modèles est le critère d'information Akaike (AIC) proposé dans [Akaike 74]. Le principe du AIC est similaire à celui du critère BIC, c'est-à-dire que le critère contient deux termes, un pour la qualité de l'ajustement du modèle et l'autre pour la pénalisation de la complexité du modèle. La seule différence est que le terme de pénalisation de l'AIC diffère de celui du BIC. Dans notre cas précis, le critère est donné par l'équation [Stoica 04] :

$$\text{AIC}(k) = -2 \ln p(\mathbf{z}|\mathcal{H}_k, \hat{\boldsymbol{\alpha}}_k) + 2M_k. \quad (2.16)$$

Similairement, la fonction de vraisemblance $p(\mathbf{z}|\mathcal{H}_k, \hat{\boldsymbol{\alpha}}_k)$ est calculée par l'équation (2.5) et nous retenons le modèle k_{AIC} qui minimise la valeur AIC :

$$k_{AIC} = \underset{k}{\text{argmin}} \text{AIC}(k) \quad (2.17)$$

pour trouver la position (x_{AIC}, y_{AIC}) de la cible.

2.6.3 Pénalisation avec informations d'empreintes digitales

Au lieu d'ajouter un terme de pénalisation sur la complexité du modèle, nous proposons de pénaliser une case si les retards de cette case n'ont pas une corrélation absolue avec les retards du signal reçu. Cette idée vient du fait que l'algorithme de localisation FMU suppose que les amplitudes des multi-trajets sont inconnues et ne prend en compte que les retards pour faire une projection sous-espace, ce qui peut être la source des ambiguïtés.

Dans l'exemple montré en figure 2.6.1, la case 1 (bonne case : position de la cible) et la case 2 (case ambiguë) ont des empreintes digitales différentes. La case 2 a un multi-trajet de plus que la case 1. De ce fait, si le signal reçu est le signal présenté dans la même figure, la bonne estimation doit choisir la

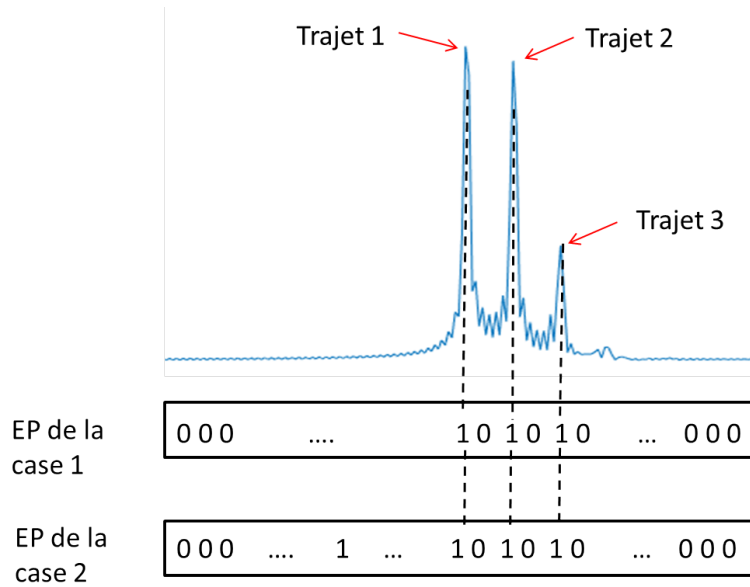


FIGURE 2.6.1 – Exemple des empreintes digitales de deux positions ambiguës.

case 1 comme la position de la cible. Or avec l'algorithme FMU, le niveau T-FMU en sortie du test est presque le même pour ces deux cases, ce qui fournit une forte ambiguïté de localisation. Avec la pénalisation issue de l'information d'empreintes digitales (ED), nous cherchons à distinguer ces deux cas de figure en comparant l'empreinte digitale des cases avec l'empreinte digitale e_c du signal reçu obtenue par un seuillage λ_e . Nous calculons ensuite la distance δ par :

$$\delta = \|e(x, y) - e_c\|^2 \quad (2.18)$$

où $e(x, y)$ est l'ED de la case (x, y) et e_c est l'ED du signal reçu \mathbf{z} . Puis nous proposons de pénaliser la vraisemblance par un terme proportionnel à cette quantité. Le critère, appelé FIC (Fingerprint Information Criterion), que nous proposons est donc donné par l'équation suivante :

$$\text{FIC}(k) = -2 \ln p(\mathbf{z} | \mathcal{H}_k, \hat{\boldsymbol{\alpha}}_k) + \alpha_e \delta(k). \quad (2.19)$$

Notons ici que deux paramètres sont à ajuster : λ_e et α_e et doivent être choisis en fonction du problème. Dans notre cas précis, en faisant plusieurs tests avec différentes valeurs de λ_e et α_e , nous avons retenu $\lambda_e = 2\sigma^2$ et $\alpha_e = 2$ qui fournissent la meilleure performance de localisation (critères présentés dans le paragraphe 2.6.4). Finalement, nous cherchons le modèle k_{FIC} qui minimise le critère FIC :

$$k_{FIC} = \underset{k}{\operatorname{argmin}} \text{FIC}(k) \quad (2.20)$$

pour trouver la position (x_{ED}, y_{ED}) de la cible.

Dans l'exemple ci-dessus, nous avons $\delta_{\text{case 1}} = 0$ et $\delta_{\text{case 2}} = 1$, en appliquant le critère FIC, la case 2 est donc pénalisée et nous devrions estimer en effet la bonne case grâce à cette pénalisation. Notons que dans ce cas, les pénalisations BIC et AIC devraient également pénaliser la case 2 par rapport à la case 1 car la case 2 a plus de trajets que la case 1. Nous allons étudier les performances des trois pénalisations considérés pour notre application de localisation urbaine dans le paragraphe suivant.

2.6.4 Résultats : diminution des ambiguïtés





FIGURE 2.6.2 – Différentes positions de la cible considérés.


Pour déterminer si les pénalisations proposées améliorent la localisation, nous estimons la probabilité de localisation sur la bonne position P_l avec MC simulations de Monte Carlo par :

$$P_l = \frac{n_b}{MC}, \quad (2.21)$$

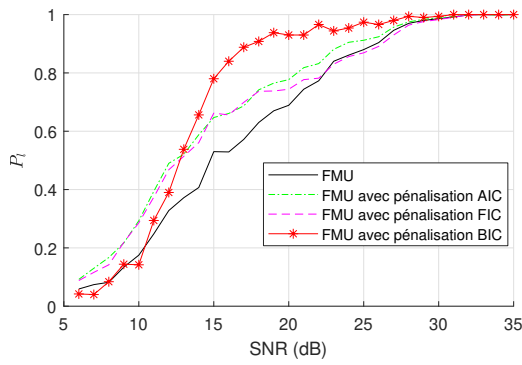
où n_b est le nombre de simulations où la position estimée correspond bien à la position de la cible. C'est-à-dire que la position réelle de la cible correspond à la case estimée par les algorithmes. Nous comparons aussi les algorithmes en calculant la REQM définie par l'équation (2.2). Pour cette mesure de performances, trois localisations de la cible NLOS différentes sont considérées : $(35, 125; 12, 125)$, $(32, 125; 14, 125)$ (utilisées dans les sections 2.5.3 et 2.5.4) et $(37, 875; 15, 875)$. Ces trois positions sont illustrées en figure 2.6.2. $MC = 1000$ simulations de Monte Carlo sont effectuées pour chaque position, ce qui permet de calculer les courbes P_l et EQM de l'algorithme FMU ainsi que des méthodes pénalisées en variant le SNR de la cible. Les résultats obtenus sont présentés en figure 2.6.3.




(a) P_l en fonction du SNR. Cible à $(35, 125; 12, 125)$.



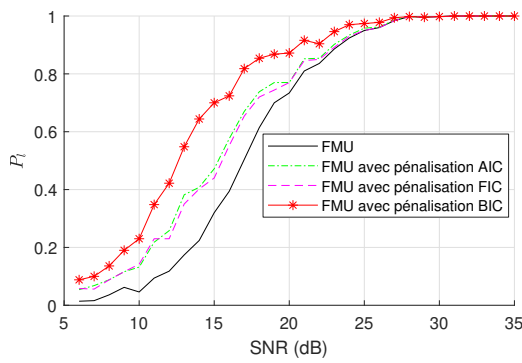
(b) REQM en fonction du SNR. Cible à $(35, 125; 12, 125)$.




(c) P_l en fonction du SNR. Cible à $(32, 125; 14, 125)$.



(d) REQM en fonction du SNR. Cible à $(32, 125; 14, 125)$.



(e) P_l en fonction du SNR. Cible à $(37, 875; 15, 875)$.



(f) REQM en fonction du SNR. Cible à $(37, 875; 15, 875)$.

FIGURE 2.6.3 – P_l et REQM en fonction du SNR pour différentes positions de la cible.

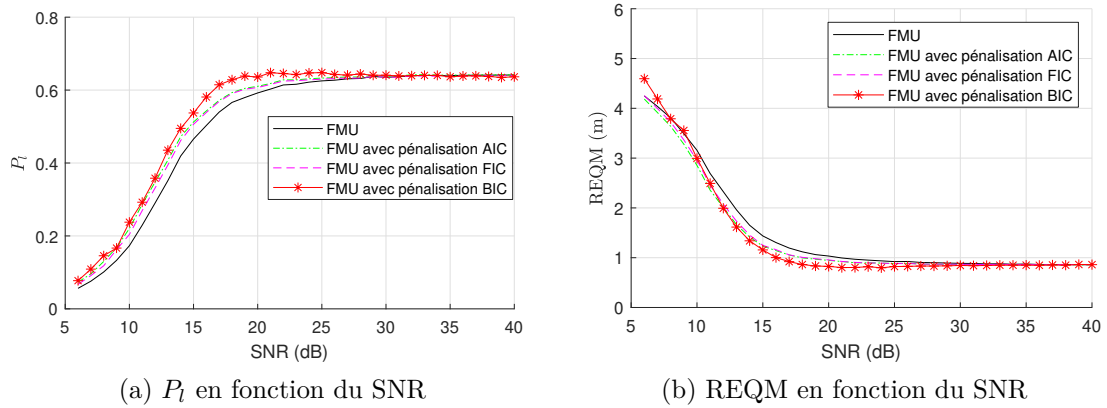


FIGURE 2.6.4 – Courbes de P_l et REQM en moyennant sur toutes les cases. Le nombre de trajets pour chaque case est choisi par l’algorithme de sélection du nombre de trajets.

Pour toutes les positions considérées, les pénalisations AIC et FIC fournissent de meilleurs performances que l’algorithme FMU simple, que ce soit en terme de probabilité de localisation P_l qu’en terme de REQM. Dans la plupart des cas, la pénalisation BIC fournit de meilleures performances que les autres. Toutefois, en position $(32, 125; 14, 125)$, la pénalisation BIC présente des performances dégradées aux faibles SNRs mais des performances plus intéressantes aux forts SNRs. Ce comportement s’explique par le phénomène d’« underfitting » bien connu du critère BIC, qui survient lorsque la pénalité domine le terme de vraisemblance [Dziak 17]. C’est effectivement le cas ici : quand le SNR du signal est faible, les variations des valeurs de vraisemblances des différents modèles sont relativement faibles par rapport au terme de pénalité. Donc la pénalisation BIC tend à sélectionner le modèle avec le moins de trajets, ce qui cause des dégradations de performance de localisation. Par contre, pour les forts SNRs, le critère BIC devient plus performant que les autres critères de pénalisations.

La même simulation est effectuée pour toutes les cases spatiales dans la zone observée. Nous présentons en figure 2.6.4 les courbes de P_l et de REQM alors obtenues en moyennant les performances obtenues dans chaque case.

Nous observons que les pénalisations BIC, AIC et FIC fournissent de meilleures performances de localisation sur toute la plage de SNRs que l’algorithme FMU sans pénalisation. Ainsi, le critère BIC fournit les meilleures améliorations parmi tous les critères. Nous pouvons donc conclure que les différentes pénalisations permettent d’améliorer la performance de localisation en diminuant les ambiguïtés.

Par ailleurs, nous pouvons noter ici que la probabilité P_l ne tend pas vers 1 quand le SNR de la cible tend vers l'infini. Ceci est essentiellement dû aux cases proches des murs pour lesquelles le nombre de trajets est trop faible ou les multi-trajets ne sont pas résolus pour permettre une bonne localisation, comme remarqué dans la section 2.5.4. Une autre raison est que nous avons limité le nombre de trajets choisis pour chaque case par l'algorithme de sélection du nombre de trajets. Cette limitation a permis d'améliorer la performance de détection mais a pu influencer sur les performances de la localisation. Pour interpréter ces influences, nous avons relancé les simulations identiques à celles de la figure 2.6.4 mais cette fois, le nombre de trajets n'est pas préalablement calculé par l'algorithme de sélection, mais simplement fourni par le tracé de rayon.

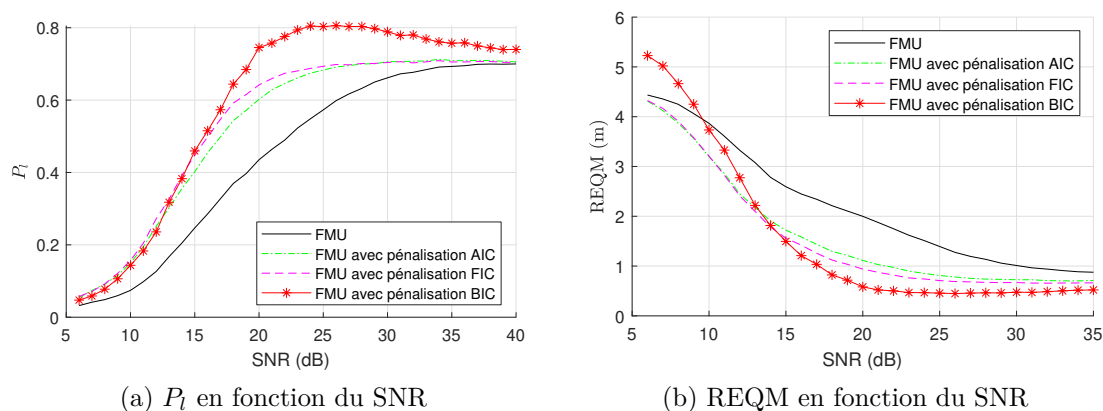


FIGURE 2.6.5 – Courbes de P_l et REQM en moyennant sur toutes les cases. Le nombre de trajets par chaque case est choisi par une simulation de tracé de rayons (sans application de l'algorithme de sélection du modèle).

Nous observons alors en figure 2.6.5 une amélioration de la probabilité de bonne localisation P_l quand le SNR tend vers infini. Par contre, cette probabilité est plus dégradée sur les SNR s plus petits. Cela veut dire que les ambiguïtés augmentent quand nous ne limitons pas le nombre de trajets. Nous constatons que le fait d'appliquer une sélection du nombre de trajets dégrade un peu la performance de localisation sur les grands SNR s mais diminuent beaucoup les ambiguïtés sur les SNR s plus petits. Par ailleurs, dans ce dernier cas de figure, nous observons que l'écart de performances entre l'algorithme FMU et les méthodes pénalisées augmente.

2.7 Conclusion

Dans ce chapitre, nous avons proposé deux solutions pour la détection et la localisation de la cible en exploitant les multi-trajets. Pour le problème de détection, nous avons observé que les algorithmes proposés fournissent généralement de meilleures performances que le filtre adapté classique dans un scénario urbain NLOS typique. En particulier, nous montrons que l'exploitation par trajets multiples peut améliorer les performances de détection tant que le SNR des trajets supplémentaires est suffisant. Nous avons également développé un algorithme spécifique pour sélectionner le nombre de multi-trajets, ce qui nous permet d'améliorer les performances de détection en optimisant la probabilité de détection. Pour le problème de localisation, les résultats obtenus par simulation montrent que les localisations cibles peuvent être estimées avec les deux algorithmes même en utilisant un modèle de propagation simple et une connaissance approximative de la géométrie de la scène. Cependant, il apparaît également que le problème de localisation adressé par l'application radar "around-the-corner" conduit à de fortes ambiguïtés spatiales inhérentes à la géométrie de la scène. Nous avons donc proposé trois corrections du test FMU pour diminuer ces ambiguïtés. Il ressort que les performances de localisation sont améliorées par ces corrections. Toutefois, les pénalisations proposées ne permettent pas de résoudre toutes les ambiguïtés, ni de les éliminer totalement, de sorte que la probabilité de fausse localisation reste non négligeable. Ces ambiguïtés représentent donc un défi restant à résoudre. Nous allons considérer dans le chapitre suivant une autre approche fondée sur des algorithmes de pistage pour lever ces ambiguïtés.

Chapitre 3

Localisation et pistage d'une cible en NLOS par filtres particulières

3.1 Introduction

Dans le chapitre précédent, nous avons proposé deux algorithmes FMU et SLC qui exploitent les multi-trajets afin de détecter et localiser une cible en NLOS. Pour ce qui concerne la localisation, la plupart du temps ces algorithmes estiment correctement la position de la cible. Cependant, le problème principal de ces deux algorithmes est la présence d'ambiguïtés importantes qui peuvent générer des fantômes ou de forts biais affectant les performances de localisation. A la fin du chapitre précédent, nous avons donc proposé une alternative à ces approches en exploitant des méthodes de sélection de modèles. Même si par ce biais nous avons pu améliorer les performances de localisation et diminuer en partie l'impact des ambiguïtés, ces dernières restent néanmoins très fortes. Ce phénomène d'ambiguïtés est également observé dans d'autres travaux exploitant des multi-trajets. Par exemple, dans [Setlur 14], où un radar à synthèse d'ouverture urbain est étudié, les deux techniques d'exploitation par multi-trajets proposées ont également fourni des images ambiguës ; et dans [Tahmoush 12], où l'objectif est de suivre les cibles dans le domaine distance-temps par l'exploitation des multi-trajets, l'approche proposée n'a pas été capable de lever les ambiguïtés pour deux traces multi-trajets présentant des distances similaires. Les ambiguïtés présentées dans plusieurs études relatives à des scènes urbaines nous ont motivé à développer des algorithmes de pistage pour les atténuer et ainsi améliorer la localisation des cibles. En effet, le pistage nous permet de prendre en compte l'évolution de la cible au cours du temps et donc potentiellement de lever les ambiguïtés qui ne sont pas cohérentes avec l'évolution de la cible. Notons que si le pistage en environnement

urbain a été étudié dans [Chakraborty 10] avec un radar aéroporté (le radar étant donc situé loin et au-dessus de la scène urbaine), ou dans [Barbosa 08] avec des capteurs multiples localisés dans la scène urbaine, l'objectif des deux articles n'était pas d'atténuer les ambiguïtés inhérentes à la propagation par multi-trajets.

Dans ce chapitre, nous présentons dans le paragraphe 3.2 les modèles d'état et de mesure spécifiques à notre problème. Nous présentons dans le paragraphe 3.3 un algorithme particulière classique applicable à notre problématique particulière. Ensuite, nous proposons deux algorithmes pour le problème de pistage : le filtre particulière GLRT et le filtre particulière Swerling I dans les paragraphes 3.4 et 3.5 respectivement. Le filtre particulière GLRT estime les amplitudes inconnues des multi-trajets au sens du maximum de vraisemblance, tandis que le filtre particulière Swerling I les intègre dans le vecteur d'état des particules et calcule la vraisemblance des mesures conditionnellement à l'état par marginalisation sur ces amplitudes. Dans le paragraphe 3.6, nous présentons deux bornes de pistage : la borne de Cramér-Rao a posteriori et la borne de Cramér-Rao a posteriori conditionnelle. Pour finir, dans le paragraphe 3.7, nous présentons les simulations effectuées et comparons les performances obtenues pour ces deux filtres par rapport aux deux bornes de Cramér-Rao calculées.

3.2 Modèle d'état et modèle de mesure

Notons \mathbf{x}_k l'état de la cible composé de sa position (x_k, y_k) et sa vitesse (\dot{x}_k, \dot{y}_k) en coordonnées cartésiennes à un instant k . La trajectoire de la cible peut être décrite par une équation linéaire classique dès lors que nous supposons un mouvement rectiligne uniforme :

$$\mathbf{x}_k = \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{b}_k, \quad (3.1)$$

où \mathbf{b}_k est le bruit d'état supposé blanc gaussien avec une matrice de covariance connue $\mathbf{Q} = \sigma_e^2 \mathbf{I}$, et \mathbf{F}_k est la matrice de transition d'état :

$$\mathbf{F}_k = \begin{bmatrix} 1 & 0 & T_r & 0 \\ 0 & 1 & 0 & T_r \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (3.2)$$

D'après le chapitre 2, l'équation de mesure peut être écrite sous la forme :

$$\mathbf{z}_k = \mathbf{R}(x_k, y_k) \boldsymbol{\alpha}(x_k, y_k) + \mathbf{n}_k. \quad (3.3)$$

La matrice $\mathbf{R}(x_k, y_k)$ dépend de la position de la cible et est fournie par un modèle de tracé de rayons utilisant la connaissance approximative de la scène.

Les amplitudes $\alpha(x_k, y_k)$ dépendent également de la position de la cible. Nous supposons que ces amplitudes sont inconnues et déterministes. Pour des raisons de simplicité, la matrice $\mathbf{R}(x_k, y_k)$ sera notée \mathbf{R}_k et les amplitudes $\alpha(x_k, y_k)$ seront notées α_k dans la suite du manuscrit mais nous n'oublierons pas qu'elles dépendent de l'état de la cible. Le modèle d'observation s'écrira donc :

$$\mathbf{z}_k = \mathbf{R}_k \alpha_k + \mathbf{n}_k, \quad (3.4)$$

où les tailles de \mathbf{R}_k et α_k dépendent de l'état \mathbf{x}_k , c'est-à-dire du nombre de trajets présents pour la position (x_k, y_k) .

L'équation de mesure est fortement non linéaire : en effet, la matrice \mathbf{R}_k dépend de manière non linéaire de la position (x_k, y_k) par le biais de la fonction d'auto-corrélation du signal émis. Par ailleurs, les amplitudes α_k dépendent de l'état \mathbf{x}_k de manière très complexe, et les tailles de la matrice \mathbf{R}_k et du vecteur α_k sont fonction du nombre de trajets pour une position donnée (x_k, y_k) , et donc dépendent également de l'état \mathbf{x}_k . Dans ce contexte, le filtre de Kalman destiné aux problèmes linéaires ne semble pas adapté au problème. Nous nous sommes donc orientés vers des solutions fondées sur un filtre particulaire. Après avoir présenté un filtre particulaire classique applicable à notre problématique, nous proposons donc dans la suite deux filtres particuliers pour traiter la non-linéarité du modèle de mesure et gérer le modèle de propagation multi-trajets.

3.3 Filtre particulaire classique

Les amplitudes α_k dépendent de la position (x_k, y_k) de la cible à l'instant k et sont normalement difficiles à modéliser en raison de paramètres d'environnement inconnus comme les pertes de propagation, les coefficients de réflexion sur des cibles ou des murs, l'angle de présentation de la cible, etc. Pour gérer ce paramètre inconnu, un filtre particulaire (FP) classique peut l'intégrer au vecteur d'état pour l'échantillonner au même titre que les autres paramètres d'intérêt [Kitagawa 98, Storvik 02]. Dans notre cas, cette stratégie suppose un comportement cohérent des amplitudes des multi-trajets dans le temps permettant de les décrire via un modèle de chaîne de Markov. Par exemple, un modèle bruité simple de type $\alpha_k^i = \alpha_{k-1}^i + \mathbf{n}_\alpha^i$ où \mathbf{n}_α^i serait un bruit blanc, comme proposé dans [Andrieu 04, Rutten 05, Lepoutre 12]. Ces amplitudes sont intégrées dans l'état des particules pour les échantillonner. Notons ζ_k^i l'état de la particule i composé de sa position et sa vitesse \mathbf{x}_k^i et des amplitudes α_k^i des différents multi-trajets correspondant à la position de la particule :

$$\zeta_k^i = \left[(\mathbf{x}_k^i)^T, (\alpha_k^i)^T \right]^T = \left[x_k^i, y_k^i, \dot{x}_k^i, \dot{y}_k^i, (\alpha_k^i)^T \right]^T. \quad (3.1)$$

Le modèle d'état pour ζ_k^i est fourni par :

$$\zeta_k = \begin{bmatrix} \mathbf{x}_k \\ \boldsymbol{\alpha}_k \end{bmatrix} = \begin{bmatrix} \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{b}_k \\ \boldsymbol{\alpha}_{k-1} + \mathbf{n}_\alpha \end{bmatrix}. \quad (3.2)$$

Les particules sont tout d'abord propagées de l'instant $k-1$ à l'instant k par le biais de la densité d'importance $q(\zeta_k^i | \zeta_{k-1}^i, \mathbf{z}_{1:k})$. Les poids w_k^i sont donnés par :

$$w_k^i \propto w_{k-1}^i \frac{p(\mathbf{z}_k | \zeta_k^i) p(\zeta_k^i | \zeta_{k-1}^i)}{q(\zeta_k^i | \zeta_{k-1}^i, \mathbf{z}_{1:k})}, \quad (3.3)$$

où w_{k-1}^i est le poids de la particule ζ_{k-1}^i à l'instant $k-1$. Un simple choix de la densité d'importance $q(\zeta_k^i | \zeta_{k-1}^i, \mathbf{z}_{1:k})$ est $p(\zeta_k^i | \zeta_{k-1}^i)$ qui est calculée directement à partir du modèle d'état (3.2). Le poids w_k^i est alors simplement proportionnel à la fonction de vraisemblance $p(\mathbf{z}_k | \zeta_k^i)$ fournie par :

$$p(\mathbf{z}_k | \zeta_k^i) \propto \exp \left(-\frac{\|\mathbf{z}_k - \mathbf{R}_k^i \boldsymbol{\alpha}_k^i\|^2}{\sigma_m^2} \right), \quad (3.4)$$

en supposant que le vecteur de bruit de mesure \mathbf{n}_k est complexe gaussien circulaire de matrice de covariance $\sigma_m^2 \mathbf{I}$.

Cependant, cette stratégie présente deux inconvénients : tout d'abord elle suppose un comportement cohérent de l'amplitude dans le temps. Toutefois ce type de modèle est peu réaliste pour notre problématique, et peut conduire à des états d'amplitudes peu performants nécessitant une augmentation du nombre de particules pour obtenir un filtre présentant un fonctionnement satisfaisant. Deuxièmement, la stratégie classique ne permet pas d'exploiter des informations sur la mesure en cours, alors qu'il a été prouvé que la densité d'importance optimale est $p(\zeta_k | \zeta_{k-1}, \mathbf{z}_k)$ et exploite donc la mesure courante [Doucet 01]. Nous proposons donc dans les sections suivantes deux filtres particuliers : le filtre particulaire GLRT qui estime les amplitudes inconnues des multi-trajets au sens du maximum de vraisemblance, et le filtre particulaire Swerling I qui les intègre dans le vecteur d'état des particules et calcule la vraisemblance $p(\mathbf{z}_k | \mathbf{x}_k^i)$ des mesures conditionnellement à l'état par marginalisation sur ces amplitudes.

3.4 Filtre particulaire GLRT

Dans cette première solution, nous proposons comme pour le filtre particulaire classique d'intégrer les amplitudes des multi-trajets dans l'état des particules pour les échantillonner. Nous considérons donc de nouveau l'état ζ_k^i défini à l'équation (3.1).

Au lieu de supposer un comportement cohérent des amplitudes des multi-trajets dans le temps comme dans le cas classique, nous proposons plutôt ici de considérer que le modèle a priori pour les amplitudes est $\alpha_k^i(m) = \rho_k^i(m) e^{j\phi_k^i(m)}$ avec $\rho_k^i(m) \sim U_{[0, \rho_{max}]}$ et $\phi_k^i(m) \sim U_{[0, 2\pi]}$, où $U_{[a, b]}$ est la distribution uniforme sur l'intervalle $[a, b]$, et où $\alpha_k^i(m)$ est la $m^{\text{ième}}$ composante du vecteur α_k^i . Ce modèle ne suppose aucune cohérence de l'amplitude au cours du temps. Ici, nous proposons de factoriser la densité d'importance de la façon suivante :

$$q(\zeta_k^i | \zeta_{k-1}^i, \mathbf{z}_{1:k}) = q(\alpha_k^i | \mathbf{x}_k^i, \mathbf{z}_k) p(\mathbf{x}_k^i | \zeta_{k-1}^i). \quad (3.1)$$

Cela signifie que la position et la vitesse de la cible sont échantillonnées selon l'équation d'état, tandis que les amplitudes des différents trajets sont échantillonnées conditionnellement à la position et à la vitesse de la cible à l'instant k et à la mesure à l'instant k . Cela permet d'exploiter certaines informations portées par la mesure en cours. Un choix possible pour $q(\alpha_k^i | \mathbf{x}_k^i, \mathbf{z}_k)$ est :

$$q(\alpha_k^i | \mathbf{x}_k^i, \mathbf{z}_k) = \mathcal{N}(\hat{\alpha}_k^i, \sigma_\alpha^2 \mathbf{I}_{[M(x_k^i, y_k^i)]}), \quad (3.2)$$

où $\hat{\alpha}_k^i$ est l'estimateur du maximum de vraisemblance de α_k^i à partir de la mesure \mathbf{z}_k conditionnellement à \mathbf{x}_k , fourni par :

$$\hat{\alpha}_k^i = (\mathbf{R}_k^H \mathbf{R}_k)^{-1} \mathbf{R}_k^H \mathbf{z}_k, \quad (3.3)$$

où σ_α^2 est un paramètre à régler et $M(x_k^i, y_k^i)$ est le nombre de trajets correspondant à la position de la particule ζ_k^i . Sous ces hypothèses préalables et compte tenu du choix de la densité d'importance, le poids de la particule i à l'instant k peut s'écrire :

$$w_k^i \propto \frac{w_{k-1}^i}{q(\alpha_k^i | \mathbf{x}_k^i, \mathbf{z}_k)} \exp\left(-\frac{\|\mathbf{z}_k - \mathbf{R}_k^i \alpha_k^i\|^2}{\sigma_m^2}\right), \quad (3.4)$$

où α_k^i est échantillonné à partir de la distribution $\mathcal{N}(\hat{\alpha}_k^i, \sigma_\alpha^2 \mathbf{I}_{[M(x_k^i, y_k^i)]})$ et $q(\alpha_k^i | \mathbf{x}_k^i, \mathbf{z}_k)$ est calculé par l'équation (3.2). Dans le cas extrême où σ_α tend vers 0, α_k^i dans l'équation (3.4) est directement donné par l'estimateur du maximum de vraisemblance de α_k^i et tous les $q(\alpha_k^i | \mathbf{x}_k^i, \mathbf{z}_k)$ sont identiques. Puis en divisant l'équation (3.4) par la probabilité de la mesure sous hypothèse qu'aucune cible n'est présente dans la scène, qui est ici identique pour toutes les particules, nous obtenons un filtre particulaire, dénoté GLRT car il fait intervenir le test statistique GLRT issu du test de détection d'une cible [Rabaste 12] :

$$w_k^i \propto w_{k-1}^i \frac{\exp\left(-\frac{\|\mathbf{z}_k - \mathbf{R}_k^i \hat{\alpha}_k^i\|^2}{\sigma_m^2}\right)}{\exp\left(-\frac{\|\mathbf{z}_k\|^2}{\sigma_m^2}\right)}. \quad (3.5)$$

L'équation (3.4) devient alors :

$$w_k^i \propto w_{k-1}^i L(\mathbf{z}_k | \zeta_k^i), \quad (3.6)$$

où

$$L(\mathbf{z}_k | \zeta_k^i) = \frac{\exp\left(-\frac{\|\mathbf{z}_k - \mathbf{R}_k^i \hat{\alpha}_k^i\|^2}{\sigma_m^2}\right)}{\exp\left(-\frac{\|\mathbf{z}_k\|^2}{\sigma_m^2}\right)} \quad (3.7)$$

est le rapport de vraisemblance généralisé pour le test de détection testant la présence d'une cible d'état ζ_k^i . Remarquons que le rapport de vraisemblance généralisé $L(\mathbf{z}_k | \zeta_k^i)$ est exactement le test de localisation FMU T_{FMU} proposé dans le chapitre 2. Les poids des particules à l'instant k sont ensuite normalisés pour que $\sum_{i=1}^N w_k^{(i)} = 1$.

Enfin, l'estimateur classique de la position de la cible est fourni par :

$$\hat{x}_k = \frac{1}{N_p} \sum_{i=1}^{N_p} w_k^i x_k^i, \quad (3.8)$$

$$\hat{y}_k = \frac{1}{N_p} \sum_{i=1}^{N_p} w_k^i y_k^i. \quad (3.9)$$

Le filtre particulière GLRT est décrit par l'Algorithme 2. A l'itération 0, l'étape d'initialisation consiste à initialiser N_p particules \mathbf{x}_0^i ($i = 1 : N_p$) réparties uniformément dans tout l'espace des positions et vitesses (x, y, v_x, v_y) : les positions sont alors définies dans la zone souhaitée tandis que les vitesses sont tirées aléatoirement de sorte que le module soit inférieur à une certaine vitesse v_{max} réaliste du contexte. Les poids des particules w_0^i sont initialisés à $\frac{1}{N_p}$.

3.5 Filtre particulière Swerling I

Dans ce paragraphe, nous proposons de considérer une autre approche pour exploiter les amplitudes inconnues des multi-trajets proposée par [Davey 12] dans le cas d'une phase inconnue seule, et étendue par [Lepoutre 16, Rabaste 12] dans le cas de cibles multiples en contexte Track-Before-Detect. Nous proposons ici d'adopter cette stratégie au cas de trajets multiples. Nous n'intégrons pas les amplitudes dans le vecteur d'état des particules : la vraisemblance $p(\mathbf{z}_k | \mathbf{x}_k^i)$ est plutôt obtenue par marginalisation sur les amplitudes complexes α_k^i . Nous avons alors :

$$p(\mathbf{z}_k | \mathbf{x}_k^i) = \int p(\mathbf{z}_k | \mathbf{x}_k^i, \alpha_k^i) p(\alpha_k^i) d\alpha_k^i \quad (3.1)$$

$$= \int \int p(\mathbf{z}_k | \mathbf{x}_k^i, \rho_k^i, \phi_k^i) p(\rho_k^i) p(\phi_k^i) d\rho_k^i d\phi_k^i, \quad (3.2)$$

Algorithme 2 : Filtre particulière GLRT à l'itération k .

Entrées : Etats et poids de N_p particules à l'itération $k - 1$:

- $$(w_{k-1}^i, \mathbf{x}_{k-1}^i)_{i=1}^{N_p}$$
- 1 **pour** $i = 1 : N_p$ **faire**
 - 2 Propagation : générer les particules ζ_k^i selon la loi $q(\zeta_k^i | \zeta_{k-1}^i, \mathbf{z}_{1:k})$ avec l'équation (3.1).
 - 3 Mise à jour : calculer les poids w_k^i par l'équation (3.4).
 - 4 **fin**
 - 5 Normaliser les poids par $w_k^i = \frac{w_{k-1}^i}{\sum_{j=1}^{N_p} w_{k-1}^j}$.
 - 6 **si** $N_{eff} < \beta N_p$ **alors**
 - 7 Rééchantillonner les particules à partir de $\sum_{i=1}^{N_p} w_k^i \delta_{\zeta_k^i}(\zeta_k)$.
 - 8 Réinitialiser les poids : $w_k^i = \frac{1}{N_p}$, $i = 1, \dots, N_p$.
 - 9 **fin**
 - 10 Retourner $(w_k^i, \zeta_k^i)_{i=1}^{N_p}$.
-

où les amplitudes complexes des trajets ont été décomposées sous la forme $\alpha_k^i = \rho_k^i \odot \exp(j\phi_k^i)$, où ρ_k^i est le vecteur contenant les modules des amplitudes et ϕ_k^i est le vecteur contenant les phases des amplitudes.

Nous supposons que ces amplitudes suivent un modèle de type Swerling I, c'est-à-dire que leur module ρ suit la même distribution de Rayleigh :

$$p(\rho) = \frac{\rho}{\sigma_\rho^2} \exp\left(-\frac{\rho^2}{2\sigma_\rho^2}\right), \quad (3.3)$$

où σ_ρ est le paramètre de la distribution de Rayleigh, tel que l'espérance $E[\rho] = 2\sigma_\rho^2$ et la phase ϕ est uniformément répartie sur $[0, 2\pi)$.

Notons que le calcul direct par la double intégration (3.2) n'est pas évident [Lepoutre 16]. Toutefois, nous remarquons que dans le cas où les amplitudes sont de type Swerling I, la mesure \mathbf{z}_k dans l'équation (3.4) peut se réécrire sous la forme :

$$\mathbf{z}_k = \sum_{j=1}^{M(x_k, y_k)} \alpha_{k,j} \mathbf{r}_{k,j} + \mathbf{n}_k, \quad (3.4)$$

où l'amplitude $\alpha_{k,j} = \rho_{k,j} \exp(j\phi_{k,j})$ du trajet j est une variable gaussienne complexe circulaire de moyenne nulle et de variance $2\sigma_\rho^2$, et $\mathbf{r}_{k,j}$ est la j -ème colonne de la matrice \mathbf{R}_k . Donc, \mathbf{z}_k qui est une somme pondérée de vecteurs gaussiens indépendants de moyenne nulle, est également un vecteur gaussien complexe de moyenne nulle avec une matrice de covariance Σ_k fournie par :

$$\mathbf{\Sigma}_k = \mathbf{Q} + \sum_{j=1}^{M(x_k, y_k)} 2\sigma_\rho^2 \mathbf{r}_{k,j} \mathbf{r}_{k,j}^H. \quad (3.5)$$

De ce fait, la vraisemblance $p(\mathbf{z}_k | \mathbf{x}_k^i)$ est directement fournie par :

$$p(\mathbf{z}_k | \mathbf{x}_k^i) \propto \frac{1}{\det(\mathbf{\Sigma}_k)} \exp\left(-\mathbf{z}_k^H \mathbf{\Sigma}_k^{-1} \mathbf{z}_k\right), \quad (3.6)$$

en remarquant que la matrice $\mathbf{\Sigma}_k$ est définie positive.

Pour le paramètre de la distribution de Rayleigh σ_ρ , nous considérons deux approches ici : soit nous le voyons comme un paramètre constant du filtre particulière et fixons sa valeur pour chaque application, soit nous l'intégrons dans l'état des particules pour l'échantillonner, ce qui est la stratégie d'un filtre particulière classique [Rutten 05].

3.5.1 Approche 1 : σ_ρ paramètre constant

Avec la première approche, le vecteur d'état des particules est le même que celui de la cible qui se compose de sa position (x_k, y_k) et ses vitesses (\dot{x}_k, \dot{y}_k) . En suivant le cadre classique du filtre particulière, les particules se propagent de l'instant $k-1$ à l'instant k en deux étapes. D'abord, l'état des particules à l'instant k est tiré aléatoirement à partir de la densité d'importance $q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k})$. Le poids pour la particule i peut être calculé par

$$w_k^i \propto w_{k-1}^i \frac{p(\mathbf{z}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k})}, \quad (3.7)$$

où w_{k-1}^i est le poids de la particule i à l'instant $k-1$. Un choix simple de la densité d'importance $q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k})$ est $p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)$, de sorte que le poids \tilde{w}_k^i est alors simplement proportionnel à la fonction de vraisemblance $p(\mathbf{z}_k | \mathbf{x}_k^i)$ fournie par :

$$p(\mathbf{z}_k | \mathbf{x}_k^i) \propto \frac{1}{\det(\mathbf{\Sigma}_k^i)} \exp\left(-\mathbf{z}_k^H (\mathbf{\Sigma}_k^i)^{-1} \mathbf{z}_k\right), \quad (3.8)$$

où $\mathbf{\Sigma}_k^i$ est la matrice de covariance associée à la particule i , calculée par l'équation (3.5).

Le filtre particulière Swerling I/ approche 1 est décrit par l'Algorithme 3. A l'itération 0, l'étape d'initialisation consiste à initialiser N_p particules \mathbf{x}_0^i ($i = 1 : N_p$) réparties uniformément dans tout l'espace des positions et vitesses (x, y, v_x, v_y) . Les poids des particules w_0^i sont initialisés à $\frac{1}{N_p}$.

Algorithme 3 : Filtre particulière Swerling I/ approche 1 à l'itération k .

Entrées : Etats et poids de N_p particules à l'itération $k - 1$:

- $$(w_{k-1}^i, \mathbf{x}_{k-1}^i)_{i=1}^{N_p}$$
- 1 **pour** $i = 1 : N_p$ **faire**
 - 2 Propagation : générer les particules \mathbf{x}_k^i selon la loi

$$q(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k}) = p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i).$$
 - 3 Calcul de la matrice de covariance

$$\Sigma_k^i = \mathbf{Q} + \sum_{j=1}^{M_i} 2(\sigma_\rho)_k^2 \mathbf{r}_{k,j}^i (\mathbf{r}_{k,j}^i)^H.$$
 - 4 Mise à jour : calculer les poids w_k^i par l'équation $w_k^i \propto w_{k-1}^i p(\mathbf{z}_k | \mathbf{x}_k^i)$
 où $p(\mathbf{z}_k | \mathbf{x}_k^i) \propto \frac{1}{\det(\Sigma_k^i)} \exp\left(-\mathbf{z}_k^H (\Sigma_k^i)^{-1} \mathbf{z}_k\right).$
 - 5 **fin**
 - 6 Normaliser les poids par $w_k^i = \frac{w_{k-1}^i}{\sum_{j=1}^{N_p} w_{k-1}^j}.$
 - 7 **si** $N_{eff} < \beta N_p$ **alors**
 - 8 Rééchantillonner les particules à partir de $\sum_{i=1}^{N_p} w_k^i \delta_{\mathbf{x}_k^i}(\mathbf{x}_k)$
 - 9 Réinitialiser les poids : $w_k^i = \frac{1}{N_p}, i = 1, \dots, N_p$
 - 10 **fin**
 - 11 Retourner $(w_k^i, \mathbf{x}_k^i)_{i=1}^{N_p}$
-

3.5.2 Approche 2 : σ_ρ variable

Avec la seconde approche, qui intègre le paramètre σ_ρ dans l'état des particules pour l'échantillonner, le vecteur d'état de la particule i à l'instant k s'exprime par $\boldsymbol{\psi}_k^i = [x_k^i, y_k^i, \dot{x}_k^i, \dot{y}_k^i, (\sigma_\rho)_k^i]^T$. Nous supposons que le modèle a priori pour le paramètre σ_ρ est un simple modèle de type :

$$(\sigma_\rho)_k = (\sigma_\rho)_{k-1} + n_\rho, \quad (3.9)$$

où n_ρ est un bruit blanc gaussien et $(\sigma_\rho)_0$ est une valeur prédéfinie. Dans ce cas là, l'équation du poids de la particule i à l'instant k est donnée par :

$$w_k^i \propto w_{k-1}^i \frac{p(\mathbf{z}_k | \boldsymbol{\psi}_k^i) p(\boldsymbol{\psi}_k^i | \boldsymbol{\psi}_{k-1}^i)}{q(\boldsymbol{\psi}_k^i | \boldsymbol{\psi}_{k-1}^i, \mathbf{z}_{1:k})}. \quad (3.10)$$

De même, nous choisissons la densité d'importance $q(\boldsymbol{\psi}_k^i | \boldsymbol{\psi}_{k-1}^i, \mathbf{z}_{1:k})$ égale à la probabilité de transition $p(\boldsymbol{\psi}_k^i | \boldsymbol{\psi}_{k-1}^i)$. L'équation précédente devient :

$$w_k^i \propto w_{k-1}^i p(\mathbf{z}_k | \boldsymbol{\psi}_k^i) \quad (3.11)$$

$$\propto w_{k-1}^i \frac{1}{\det(\Sigma_k^i)} \exp\left(-\mathbf{z}_k^H (\Sigma_k^i)^{-1} \mathbf{z}_k\right), \quad (3.12)$$

avec

$$\Sigma_k^i = \mathbf{Q} + \sum_{j=1}^{M_i} 2 \left(\sigma_\rho^i \right)_k^2 \mathbf{r}_{k,j}^i \left(\mathbf{r}_{k,j}^i \right)^H. \quad (3.13)$$

Enfin, pour ces deux approches, l'estimateur de la position de la cible est classiquement fourni par les équations (3.8) et (3.9).

Le filtre particulière Swerling I/ approche 2 est décrit par l'Algorithme 4. A l'itération 0, l'étape de l'initialisation consiste à initialiser N_p particules ψ_0^i ($i = 1 : N_p$) dont la position (x_0^i, y_0^i) et la vitesse $((v_x)_0^i, (v_y)_0^i)$ sont réparties uniformément dans tout l'espace (x, y, v_x, v_y) et le paramètre σ_ρ est initialisé pour une valeur prédéfinie ou tirée aléatoirement sur un intervalle prédéfini (voir le paragraphe 3.7.3.2). Les poids des particules w_0^i sont initialisés à $\frac{1}{N_p}$.

Algorithme 4 : Filtre particulière Swerling I/ approche 2 à l'itération k .

Entrées : Etats et poids de N_p particules à l'itération $k - 1$:

- $$(w_{k-1}^i, \psi_{k-1}^i)_{i=1}^{N_p}$$
- 1 **pour** $i = 1 : N_p$ **faire**
 - 2 Propagation : générer les particules ψ_k^i selon la loi
 $q(\psi_k^i | \psi_{k-1}^i, \mathbf{z}_{1:k}) = p(\psi_k^i | \psi_{k-1}^i).$
 - 3 Calcul de la matrice de covariance
 $\Sigma_k^i = \mathbf{Q} + \sum_{j=1}^{M_i} 2 \left(\sigma_\rho^i \right)_k^2 \mathbf{r}_{k,j}^i \left(\mathbf{r}_{k,j}^i \right)^H$. Mise à jour : calculer les poids
 w_k^i par l'équation $w_k^i \propto w_{k-1}^i \frac{1}{\det(\Sigma_k^i)} \exp \left(-\mathbf{z}_k^H \left(\Sigma_k^i \right)^{-1} \mathbf{z}_k \right).$
 - 4 **fin**
 - 5 Normaliser les poids par $w_k^i = \frac{w_k^i}{\sum_{j=1}^{N_p} w_k^j}$.
 - 6 **si** $N_{eff} < \beta N_p$ **alors**
 - 7 Rééchantillonner les particules à partir de $\sum_{i=1}^{N_p} w_k^i \delta_{\psi_k^i}(\psi_k)$
 - 8 Réinitialiser les poids : $w_k^i = \frac{1}{N_p}$, $i = 1, \dots, N_p$
 - 9 **fin**
 - 10 Retourner $(w_k^i, \psi_k^i)_{i=1}^{N_p}$
-

3.6 Bornes de Cramér-Rao en pistage

Afin d'avoir une idée de l'optimalité des performances des deux algorithmes de pistage proposés, nous examinons dans cette section deux bornes de Cramér-

Rao dédiées à notre problématique. Pour cela, nous rappelons dans le paragraphe la borne de Cramér-Rao classique 3.6.1, puis présentons dans les paragraphes 3.6.2 et 3.6.3 les bornes de pistage : borne de Cramér-Rao a posteriori et borne de Cramér-Rao a posteriori conditionnelle respectivement.

3.6.1 Borne de Cramér-Rao classique

Dans les modèles statistiques invariants dans le temps, l'inégalité bayésienne de Cramér-Rao montre que l'erreur quadratique moyenne de tout estimateur sans biais $\hat{\mathbf{x}}(\mathbf{z})$ ne peut pas être inférieure à une borne [Van Trees 04], donnée par :

$$E \left\{ (\hat{\mathbf{x}}(\mathbf{z}) - \mathbf{x}) (\hat{\mathbf{x}}(\mathbf{z}) - \mathbf{x})^T \right\} \geq \mathbf{J}^{-1}, \quad (3.1)$$

où \mathbf{J} est la matrice d'information de Fisher dont la composante (i, j) est définie par :

$$J_{ij} = E \left\{ -\frac{\partial^2 \ln p(\mathbf{x}, \mathbf{z})}{\partial x_i \partial x_j} \right\} \quad i, j = 1, 2, \dots, \quad (3.2)$$

en supposant que les dérivations et les espérances dans les équations (3.1) et (3.2) existent. L'équation (3.2) peut aussi être écrite sous la forme :

$$\mathbf{J} = E \left\{ -\Delta_{\mathbf{x}}^{\mathbf{x}} \ln p(\mathbf{x}, \mathbf{z}) \right\}, \quad (3.3)$$

où l'opérateur $\Delta_{\mathbf{u}}^{\mathbf{v}}$ est défini par :

$$\nabla_{\mathbf{u}} = \left[\frac{\partial}{\partial u_1}, \dots, \frac{\partial}{\partial u_{n_u}} \right]^T \quad (3.4)$$

$$\Delta_{\mathbf{u}}^{\mathbf{v}} = \nabla_{\mathbf{u}} \nabla_{\mathbf{v}}^T. \quad (3.5)$$

3.6.2 Borne de Cramér-Rao a posteriori (BCRP)

Dans le contexte des systèmes variables dans le temps, plusieurs bornes inférieures pour les systèmes dynamiques non linéaires sont proposées dans la littérature, la plupart des cas pour les systèmes à temps continu [Kerr 89]. Les bornes pour les systèmes à temps discret, comme ce que nous considérons, sont quant à elles peu étudiées [Tichavsky 98]. Nous nous intéressons à deux bornes : la borne de Cramér-Rao a posteriori (présentée à ce paragraphe 3.6.2) et la borne de Cramér-Rao a posteriori conditionnelle (présentée au paragraphe 3.6.3).

En calculant la borne de Cramér-Rao de notre problème de pistage, nous notons $\mathbf{x}_{0:k}$ le vecteur de dimension $(k+1)n_x$ comprenant tous les états de

la cible jusqu'à l'instant k , où n_x représente la dimension du vecteur d'état x . Nous notons $\mathbf{J}(\mathbf{x}_{0:k})$ la matrice d'information de Fisher du vecteur d'état $\mathbf{x}_{0:k}$ dérivée à partir de la densité de probabilité jointe $p(\mathbf{x}_{0:k}, \mathbf{z}_{1:k})$, la borne de Cramér-Rao est alors fournie par :

$$E \left\{ (\hat{\mathbf{x}}_{0:k}(\mathbf{z}_{1:k}) - \mathbf{x}_{0:k}) (\hat{\mathbf{x}}_{0:k}(\mathbf{z}_{1:k}) - \mathbf{x}_{0:k})^T \right\} \geq \mathbf{J}^{-1}(\mathbf{x}_{0:k}). \quad (3.6)$$

La densité de probabilité jointe $p(\mathbf{x}_{0:k}, \mathbf{z}_{1:k})$ peut être calculée par

$$p(\mathbf{x}_{0:k}, \mathbf{z}_{1:k}) = p(x_0) \prod_{i=1}^k p(x_i | x_{i-1}) \prod_{j=1}^k p(z_j | x_j). \quad (3.7)$$




FIGURE 3.6.1 – Structure de l'inverse de la matrice de Fisher $\mathbf{J}^{-1}(\mathbf{x}_{0:k})$.

Soit \mathbf{K}_k la matrice telle que \mathbf{K}_k^{-1} est égale à la sous-matrice de dimension $n_x \times n_x$ du coin inférieur droit de la matrice $\mathbf{J}^{-1}(\mathbf{x}_{0:k})$ (figure 3.6.1). Alors l'erreur quadratique moyenne de l'estimation de \mathbf{x}_k est bornée par \mathbf{K}_k^{-1} [Tichavsky 98]. La matrice \mathbf{K}_k^{-1} peut être calculée par l'inversion de la matrice $\mathbf{J}(\mathbf{x}_{0:k})$ de dimension $(k+1)n_x \times (k+1)n_x$. Toutefois, la dimension de la matrice $\mathbf{J}(\mathbf{x}_{0:k})$ augmente au cours du temps, ce qui rend cette inversion très gourmande en temps de calcul. Heureusement il est possible de calculer \mathbf{K}_k par une méthode récursive [Tichavsky 98] :

$$\mathbf{K}_{k+1} = \mathbf{D}_k^{22} - \mathbf{D}_k^{21} (\mathbf{K}_k + \mathbf{D}_k^{11})^{-1} \mathbf{D}_k^{12}, \quad (3.8)$$

où

$$\mathbf{D}_k^{11} = E \left\{ -\Delta_{\mathbf{x}_k}^{\mathbf{x}_k} \ln p(\mathbf{x}_{k+1} | \mathbf{x}_k) \right\}, \quad (3.9)$$

$$\mathbf{D}_k^{12} = E \left\{ -\Delta_{\mathbf{x}_k}^{\mathbf{x}_{k+1}} \ln p(\mathbf{x}_{k+1} | \mathbf{x}_k) \right\} = (\mathbf{D}_k^{21})^T, \quad (3.10)$$

$$\mathbf{D}_k^{22} = E \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} [\ln p(\mathbf{x}_{k+1} | \mathbf{x}_k) + \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})] \right\}. \quad (3.11)$$

Pour appliquer la borne dans notre cas où le modèle d'état est linéaire et le bruit de modèle est supposé additif blanc gaussien de matrice de covariance \mathbf{Q}_k , nous avons :

$$p(\mathbf{x}_{k+1}|\mathbf{x}_k) = \frac{1}{(2\pi)^{n_x/2}|\mathbf{Q}_k|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x}_{k+1} - \mathbf{F}_k\mathbf{x}_k)^T \mathbf{Q}_k^{-1}(\mathbf{x}_{k+1} - \mathbf{F}_k\mathbf{x}_k)\right), \quad (3.12)$$

et donc :

$$\ln p(\mathbf{x}_{k+1}|\mathbf{x}_k) = c - \frac{1}{2}(\mathbf{x}_{k+1} - \mathbf{F}_k\mathbf{x}_k)^T \mathbf{Q}_k^{-1}(\mathbf{x}_{k+1} - \mathbf{F}_k\mathbf{x}_k). \quad (3.13)$$

Nous en déduisons :

$$\mathbf{D}_k^{11} = \mathbf{F}_k^T \mathbf{Q}_k^{-1} \mathbf{F}_k, \quad (3.14)$$

$$\mathbf{D}_k^{12} = -\mathbf{F}_k^T \mathbf{Q}_k^{-1}, \quad (3.15)$$

$$\mathbf{D}_k^{22} = \mathbf{Q}_k^{-1} + E\left\{-\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})\right\}. \quad (3.16)$$

En injectant ces équations dans l'équation (3.8) et en utilisant le lemme d'inversion matricielle $(\mathbf{A} + \mathbf{UCV})^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{U}(\mathbf{C}^{-1} + \mathbf{VA}^{-1}\mathbf{U})^{-1}\mathbf{VA}^{-1}$, nous avons :

$$\mathbf{K}_{k+1} = \mathbf{Q}_k^{-1} + E\left\{-\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})\right\} - \mathbf{Q}_k^{-1} \mathbf{F}_k^T \left(\mathbf{K}_k + \mathbf{F}_k^T \mathbf{Q}_k^{-1} \mathbf{F}_k\right)^{-1} \mathbf{F}_k^T \mathbf{Q}_k^{-1} \quad (3.17)$$

$$= \left(\mathbf{Q}_k + \mathbf{F}_k \mathbf{K}_k^{-1} \mathbf{F}_k^T\right)^{-1} + E\left\{-\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})\right\} \quad (3.18)$$

Donc, comme les matrices \mathbf{Q}_k et \mathbf{F}_k sont connues, le calcul récursif ne nécessite de calculer que $E\left\{-\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})\right\}$. Dans notre cas particulier, la vraisemblance $p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})$ peut s'exprimer par :

$$p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1}) = \exp\left(-\frac{\|\mathbf{z}_{k+1} - \mathbf{R}_{k+1}(\mathbf{x}_{k+1})\boldsymbol{\alpha}_{k+1}(\mathbf{x}_{k+1})\|^2}{\sigma_m^2}\right). \quad (3.19)$$

Rappelons que $\mathbf{R}_{k+1}(\mathbf{x}_{k+1})$ et $\boldsymbol{\alpha}_{k+1}(\mathbf{x}_{k+1})$ dépendent de \mathbf{x}_{k+1} de manière complexe et sont très difficiles à exprimer sous forme d'une expression explicite. Pour cette raison, le terme $E\left\{-\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})\right\}$ ne pourra pas s'écrire avec une simple expression analytique et sera calculé à l'aide d'outils de calculs numériques.

Pour ce faire, nous calculons par simulation $\ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})$ sur une maille fine discrétisée de l'espace \mathbb{X} contenant le vecteur \mathbf{x}_{k+1} , puis nous calculons

$$\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})$$

grâce à des calculs numériques de gradient. $E \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) \right\}$ est facilement déduite par une moyenne sur toute la maille de l'espace \mathbb{X} . Notons que d'après l'équation (3.19), nous constatons que $\ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1})$ ne dépend que de x_{k+1} et y_{k+1} . Par conséquent, dans le cas où nous ne nous intéressons qu'à l'estimation de la position de la cible et pas de ses vitesses, la discrétisation peut se faire sur l'espace 2D \mathbb{X}' contenant x_{k+1} et y_{k+1} . Cette discrétisation peut donc être effectuée exactement comme la discrétisation faite dans les chapitres précédents sur la zone observée en x et en y .

3.6.3 Borne de Cramér-Rao a posteriori conditionnelle (BCRPC)

A l'instant donné k , la borne BCRP est calculée en prenant la moyenne sur les mesures et les états jusqu'à cet instant. Il en résulte que la borne calculée n'est pas toujours représentative, surtout si des mesures sont disponibles, par exemple, les mesures jusqu'à l'instant k $\mathbf{z}_{1:k}$. Dans ce paragraphe, nous présentons la borne de Cramér-Rao a posteriori conditionnelle (BCRPC) qui prend en compte les mesures antérieures disponibles [Zuo 11, Zheng 12].

L'estimateur conditionnel $\hat{\mathbf{x}}_{0:k+1}(\mathbf{z}_{k+1} | \mathbf{z}_{1:k})$ est défini par une fonction de la mesure observée \mathbf{z}_{k+1} étant donné que les mesures $\mathbf{z}_{1:k}$ sont disponibles. L'erreur quadratique moyenne de l'estimateur conditionnel à l'instant $k + 1$ peut être définie par :

$$\begin{aligned} \text{EQM}(\hat{\mathbf{x}}_{0:k+1}(\mathbf{z}_{1:k})) &= E \left\{ (\hat{\mathbf{x}}_{0:k+1} - \mathbf{x}_{0:k+1}) (\hat{\mathbf{x}}_{0:k+1} - \mathbf{x}_{0:k+1})^T | \mathbf{z}_{1:k} \right\} \quad (3.20) \\ &= \int (\hat{\mathbf{x}}_{0:k+1} - \mathbf{x}_{0:k+1}) (\hat{\mathbf{x}}_{0:k+1} - \mathbf{x}_{0:k+1})^T p_{k+1}^c d\mathbf{x}_{0:k+1} d\mathbf{z}_{k+1}, \quad (3.21) \end{aligned}$$

où $p_{k+1}^c = p(\mathbf{x}_{0:k+1}, \mathbf{z}_{k+1} | \mathbf{z}_{1:k})$.

Notons $\mathbf{I}(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k})$ la matrice d'information de Fisher conditionnelle de l'estimateur du vecteur d'état $\mathbf{x}_{0:k+1}$:

$$\mathbf{I}(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k}) = E \left\{ -\Delta_{\mathbf{x}_{0:k+1}}^{\mathbf{x}_{0:k+1}} \ln p_{k+1}^c | \mathbf{z}_{1:k} \right\} \quad (3.22)$$

$$= - \int \left(\Delta_{\mathbf{x}_{0:k+1}}^{\mathbf{x}_{0:k+1}} \ln p_{k+1}^c \right) p_{k+1}^c d\mathbf{x}_{0:k+1} d\mathbf{z}_{k+1}. \quad (3.23)$$

Nous pouvons en déduire la borne de Cramér-Rao a posteriori conditionnelle [Zuo 11] :

$$E \left\{ (\hat{\mathbf{x}}_{0:k+1} - \mathbf{x}_{0:k+1}) (\hat{\mathbf{x}}_{0:k+1} - \mathbf{x}_{0:k+1})^T | \mathbf{z}_{1:k} \right\} \geq \mathbf{I}^{-1}(\mathbf{x}_{0:k+1} | \mathbf{z}_{1:k}). \quad (3.24)$$

De même que pour la BCRP, le coût de calcul de cette matrice croît rapidement avec k .

Notons $\mathbf{L}(\mathbf{x}_{k+1}|\mathbf{z}_{1:k})$ la matrice d'information de Fisher conditionnelle de l'estimateur du vecteur d'état \mathbf{x}_{k+1} . Donc $\mathbf{L}^{-1}(\mathbf{x}_{k+1}|\mathbf{z}_{1:k})$ est égale à la sous-matrice de dimension $n_x \times n_x$ au coin inférieur droit de la matrice $\mathbf{I}^{-1}(\mathbf{x}_{0:k+1}|\mathbf{z}_{1:k})$. $\mathbf{L}(\mathbf{x}_{k+1}|\mathbf{z}_{1:k})$ peut être calculée par une double formule récursive [Zuo 11]. [Zheng 12] propose une version simplifiée de ce calcul, solution que nous retenons par souci de simplicité. Par définition, $\mathbf{L}^{-1}(\mathbf{x}_{k+1}|\mathbf{z}_{1:k})$ est une borne de l'erreur quadratique moyenne de l'estimateur de \mathbf{x}_{k+1} conditionnellement à $\mathbf{z}_{1:k}$. Il est démontré que $\mathbf{L}(\mathbf{x}_{k+1}|\mathbf{z}_{1:k})$ peut être approchée par la formule récursive suivante [Zheng 12] :

$$\mathbf{L}(\mathbf{x}_{k+1}|\mathbf{z}_{1:k}) \approx \mathbf{B}_k^{22} - \mathbf{B}_k^{21} \left(\mathbf{B}_k^{11} + \mathbf{L}(\mathbf{x}_k|\mathbf{z}_{1:k-1}) \right)^{-1} \mathbf{B}_k^{12} \quad (3.25)$$

où :

$$\mathbf{B}_k^{11} = E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_k}^{\mathbf{x}_k} \ln p(\mathbf{x}_{k+1}|\mathbf{x}_k) \right\} \quad (3.26)$$

$$\mathbf{B}_k^{12} = E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_k}^{\mathbf{x}_{k+1}} \ln p(\mathbf{x}_{k+1}|\mathbf{x}_k) \right\} = \left(\mathbf{B}_k^{21} \right)^T \quad (3.27)$$

$$\mathbf{B}_k^{22} = E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} [\ln p(\mathbf{x}_{k+1}|\mathbf{x}_k) + \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})] \right\}. \quad (3.28)$$

Comme pour le calcul de la borne non conditionnelle, comme le modèle d'état est linéaire et le bruit de modèle est supposé additif blanc gaussien de matrice de covariance \mathbf{Q}_k , il vient que :

$$\mathbf{L}(\mathbf{x}_{k+1}|\mathbf{z}_{1:k}) \approx \left(\mathbf{Q}_k + \mathbf{F}_k \left(\mathbf{L}(\mathbf{x}_k|\mathbf{z}_{1:k-1}) \right)^{-1} \mathbf{F}_k^T \right)^{-1} + E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1}) \right\}. \quad (3.29)$$

Le calcul récursif revient à calculer $E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1}) \right\}$. Comme expliqué dans le paragraphe précédent, le calcul de $\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1})$ ne peut se faire que numériquement en discrétisant l'espace observé. Ensuite, la moyenne $E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1}) \right\}$ est calculée par une approche de type filtre particulaire décrite dans [Zuo 11]. L'idée fondamentale de cette approche vient de la factorisation de p_{k+1}^c :

$$p_{k+1}^c = p(\mathbf{x}_{0:k+1}, \mathbf{z}_{k+1}|\mathbf{z}_{1:k}) \quad (3.30)$$

$$= p(\mathbf{x}_{0:k+1}|\mathbf{z}_{1:k+1})p(\mathbf{z}_{k+1}|\mathbf{z}_{1:k}) \quad (3.31)$$

où la densité a posteriori $p(\mathbf{x}_{0:k}|\mathbf{z}_{1:k})$ peut être approchée par les particules :

$$p(\mathbf{x}_{0:k}|\mathbf{z}_{1:k}) \approx \sum_{l=1}^{N_p} w_k^l \delta_{\mathbf{x}_{0:k}}^l(\mathbf{x}_{0:k}). \quad (3.32)$$

Ensuite, il est démontré que la densité p_{k+1}^c peut s'approcher par :

$$p_{k+1}^c \approx \sum_{l=1}^{N_p} w_k^l \delta_{\mathbf{x}_{0:k+1}}^{(l)}(\mathbf{x}_{0:k+1}) p(\mathbf{z}_{k+1}|\mathbf{x}_{k+1}^l). \quad (3.33)$$

Il vient donc que l'espérance $E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) \right\}$ peut être calculée en utilisant les particules utilisées pour représenter la densité p_{k+1}^c comme suit :

$$E_{p_{k+1}^c} \left\{ -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}) \right\} \approx \int \sum_{l=1}^{N_p} w_k^l g(\mathbf{x}_{k+1}^l) p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}^l) d\mathbf{z}_{k+1}, \quad (3.34)$$

où

$$g(\mathbf{x}_{k+1}) = -\Delta_{\mathbf{x}_{k+1}}^{\mathbf{x}_{k+1}} \ln p(\mathbf{z}_{k+1} | \mathbf{x}_{k+1}). \quad (3.35)$$

L'intégrale de l'équation (3.34) est calculée de façon numérique.

3.7 Simulation et résultats

3.7.1 Description de la simulation

Les performances de localisation des filtres particulières sont évaluées par des simulations pour le scénario d'intersection urbaine simple montré dans la figure 3.7.1.




FIGURE 3.7.1 – Scénario d'une intersection urbaine typique considéré

Les paramètres du radar sont choisis comme au paragraphe 2.5.1. Pour chacune des $N_{MC} = 1000$ simulations de Monte Carlo exécutées, $N_p = 1600$ particules (N_p étant aussi égal au nombre de cases discrétisées dans la zone observée) sont initialisées pour que leur position soit uniformément répartie dans la zone d'intérêt (zone hachurée dans la figure 3.7.1) et que leur vitesse soit uniformément tirée dans l'intervalle $[-4; 4]$ m/s. La matrice \mathbf{R} correspondant à chaque particule à l'instant k peut être calculée par un modèle de tracé de rayons. Cependant, le calcul des matrices \mathbf{R} pour toutes les particules à chaque instant est très coûteux. Donc, afin d'accélérer le processus, nous proposons de pré-calculer les matrices \mathbf{R} pour les petites cases discrétisées à partir

de la zone d'intérêt. Nous associons alors à une particule localisée dans une case donnée la matrice \mathbf{R} calculée au centre de cette case. Dans la simulation, nous discrétisons la zone en carrés de taille $0,25 \text{ m} \times 0,25 \text{ m}$, ce qui est égal à la moitié de la résolution distance du radar. Nous examinons deux trajectoires différentes de la cible (cf. figure 3.7.2) :

- Trajectoire 1 : la cible se déplace de la position $(32; 16, 25)$ à la position $(35; 16, 25)$ avec une vitesse constante : $\dot{x}_k = 2 \text{ m/s}$ et $\dot{y}_k = 0$.
- Trajectoire 2 : la cible se déplace de la position $(38; 14, 25)$ à la position $(36, 5; 15, 75)$ avec une vitesse constante : $\dot{x}_k = -1 \text{ m/s}$ et $\dot{y}_k = 1 \text{ m/s}$.

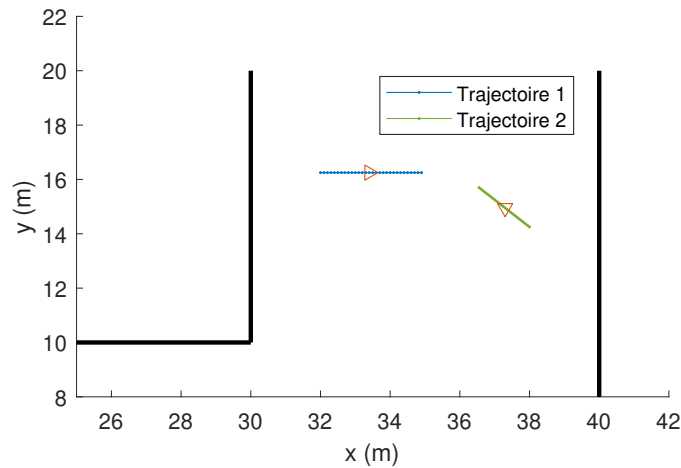


FIGURE 3.7.2 – Schéma des deux trajectoires examinées.

La période de répétition des mesures est fixée à 50 ms , de sorte que 30 itérations sont exécutées le long de la trajectoire de la cible. Pour évaluer les performances du filtre particulaire, le rapport signal à bruit (SNR) de la cible est fixé à une valeur constante pour toutes les positions de sa trajectoire en faisant varier l'amplitude κ de la cible. Nous examinons deux valeurs de SNR différentes : 10 dB et 15 dB .

3.7.2 Estimation de la position de la cible avec le filtre particulaire GLRT

La figure 3.7.3 montre la racine de l'erreur quadratique moyenne (REQM) obtenue pour le filtre particulaire GLRT avec différentes valeurs du paramètre σ_α dans le cas où la cible se déplace selon la trajectoire 1 et le SNR de la cible est à 10 dB . Notons que la définition de SNR ici est toujours celle définie dans le paragraphe 2.5.3. A partir de cette figure, il apparaît que les plus petites valeurs de σ_α fournissent les meilleures performances. Le filtre particulaire GLRT

décrit par l'équation (3.6) qui correspond à $\sigma_\alpha = 0$ fournit les meilleures performances. Ces courbes sont également comparées à celles de l'algorithme de localisation FMU proposé dans le chapitre 2 et au filtre particulaire classique décrit en section 3.3. Comme mentionné dans ce dernier chapitre, l'algorithme de localisation FMU peut générer de fortes ambiguïtés à cause de la géométrie de la scène. Surtout dans cette simulation, où le SNR de la cible est assez faible, ces ambiguïtés peuvent générer un biais important et de grandes erreurs de localisation pour certaines positions. Ceci explique pourquoi la REQM de l'algorithme de localisation FMU est assez importante, entre 2 et 4 m. En appliquant le filtre particulaire GLRT proposé, nous observons une amélioration significative de la REQM après seulement quelques itérations. Cette amélioration montre que la prise en compte de la dynamique de la cible pour le filtre particulaire permet de lever assez rapidement les ambiguïtés de localisation. Nous observons également que le filtre GLRT fournit de meilleures performances que le filtre particulaire classique pour un même nombre de particules. Cela peut être expliqué par deux raisons : premièrement, le modèle d'amplitude du filtre classique conduit à des tirages d'amplitudes moins performants que le filtre GLRT ; de plus, le filtre classique n'exploite pas d'informations sur la mesure en cours pour calculer la densité d'importance contrairement au filtre GLRT.




FIGURE 3.7.3 – Comparaison de la REQM du filtre particulaire GLRT avec différentes valeurs de σ_α , celle du filtre particulaire classique et celle de la localisation sans pistage (FMU) pour la trajectoire 1. SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.

Pour illustrer l'atténuation de l'ambiguïté, nous montrons en figure 3.7.4(a) la sortie de l'algorithme de localisation FMU pour toutes les cases position de la zone observée, et en figure 3.7.4(b) le poids des particules avant l'étape de ré-échantillonnage lorsque la cible est à la position (32, 16.25), la première po-

sition de sa trajectoire. À sa première itération, le filtre particulaire fournit une image d'ambiguïté similaire à celle de l'algorithme de localisation FMU car, à ce moment, le filtre particulaire partage la même information que l'algorithme de localisation. La figure 3.7.5 montre une comparaison similaire lorsque la cible est cette fois localisée au milieu de sa trajectoire. L'algorithme de localisation montre encore de fortes ambiguïtés tandis que le filtre particulaire fournit une remarquable réduction de l'ambiguïté. La plupart des particules sont concentrées autour de la position réelle de la cible.




FIGURE 3.7.4 – Résultat de la localisation FMU et du filtre particulaire GLRT quand la cible est à la position (32, 16.25) (première itération). Le cercle noir indique la vraie position de la cible.




FIGURE 3.7.5 – Résultat de la localisation FMU et du filtre particulaire GLRT quand la cible est à la position (33, 5; 16, 25) (16-ème itération). Le cercle noir indique la vraie position de la cible.

Nous faisons maintenant la même simulation que celle montrée en figure 3.7.3

dans le cas où la cible se déplace selon la trajectoire 1 et son SNR est à 15 dB (figure 3.7.6) et où la cible se déplace selon la trajectoire 2 et son SNR à 10 dB (figure 3.7.7). Nous constatons de nouveau que $\sigma_\alpha = 0$ fournit les meilleures performances qui sont significativement améliorées par rapport à l'algorithme de localisation FMU. Par ailleurs, nous observons que l'augmentation du SNR a pour effet d'accélérer la convergence du filtre particulaire GLRT.




FIGURE 3.7.6 – Comparaison de la REQM du filtre particulaire avec différentes valeurs de σ_α , celle du filtre particulaire classique et celle de la localisation sans pistage (FMU) pour la trajectoire 1. SNR=15 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.

3.7.3 Estimation de la position de la cible avec le filtre particulaire Swerling I

Nous nous plaçons maintenant dans le cas où le modèle considéré pour le filtre particulaire obéit à une loi d'amplitude de type Swerling I et considérons les deux approches présentées dans le paragraphe 3.5 pour trois cas de figures de la cible comme dans le paragraphe 3.7.2. Pour chaque approche, nous réalisons des simulations de Monte Carlo pour évaluer l'impact des paramètres sur les performances des filtres. En fin de section, nous comparons les performances du filtre particulaire Swerling I pour les deux approches avec le filtre particulaire GLRT.

3.7.3.1 Approche 1 :

Selon cette première approche, σ_ρ est considéré comme un paramètre constant du filtre particulaire. Plusieurs valeurs de σ_ρ sont considérées pour la configuration décrite dans le paragraphe 3.7.1. Les courbes de REQM obtenues pour

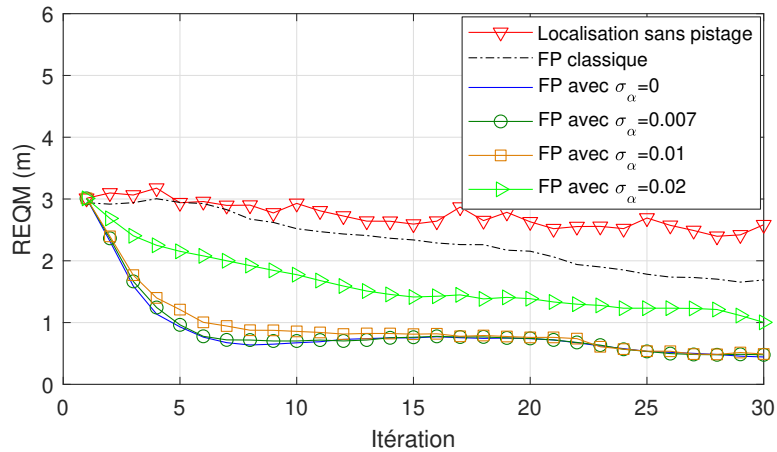


FIGURE 3.7.7 – Comparaison de la REQM du filtre particulaire avec différentes valeurs de σ_α , celle du filtre particulaire classique et celle de la localisation sans pistage (FMU) pour la trajectoire 2. SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.


le filtre particulaire Swerling I sont présentées sur la figure 3.7.8a pour les différentes valeurs de σ_ρ dans le cas où la cible se déplace selon la trajectoire 1 avec un SNR égal à 10 dB.

D'après cette figure, nous observons tout d'abord que le filtre converge pour les différentes valeurs de σ_ρ . Pourtant les performances d'estimation obtenues à la fin de la trajectoire de la cible sont différentes d'une courbe à l'autre. Nous constatons que $\sigma_\rho = 0,002$ fournit le meilleur compromis entre deux critères : la plus petite valeur de la REQM en fin de la trajectoire et la vitesse de convergence du filtre. Nous remarquons aussi que pour $\sigma_\rho < 0,002$, le filtre particulaire converge plus lentement, et que pour $\sigma_\rho > 0,002$, les performances d'estimation après convergence sont moins bonnes. Nous observons la même tendance dans le cas où le SNR de la cible est à 15 dB (figure 3.7.8b). Pourtant, l'écart entre les courbes dans ce cas est diminué. Avec la trajectoire 2, nous constatons de nouveau cette tendance (3.7.8c). Toutefois, il semble que cette fois, $\sigma_\rho = 0,003$ fournit une meilleure courbe de REQM que $\sigma_\rho = 0,002$.


3.7.3.2 Approche 2 :

Selon la deuxième approche, σ_ρ est intégré dans le vecteur d'état. De même, dans ce cas là, nous traçons les courbes de REQM obtenues pour le filtre particulaire Swerling I avec différentes initialisations de $(\sigma_\rho)_0^i$:


- $(\sigma_\rho)_0^i = 0,001$ pour toutes les particules i ;
- $(\sigma_\rho)_0^i = 0,01$ pour toutes les particules i ;



(a) Trajectoire 1 / SNR = 10 dB.



(b) Trajectoire 1 / SNR = 15 dB.




(c) Trajectoire 2 / SNR = 10 dB.


FIGURE 3.7.8 – Performances du filtre particulaire Swerling I (approche 1) pour différentes configurations examinées. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.

- $(\sigma_\rho)_0^i = 0,02$ pour toutes les particules i ;
- les $(\sigma_\rho)_0^i$ sont tirés aléatoirement selon une distribution uniforme sur l'intervalle $[0,001; 0,02]$,

pour les trois cas de figure considérés : trajectoire 1/ SNR=10 dB, trajectoire 1/ SNR=15dB et trajectoire 2/SNR=10dB.



(a) Évolution de la REQM.




(b) Évolution de $E[\sigma_\rho]$ au cours du temps.


FIGURE 3.7.9 – Filtre particulaire Swerling I/ approche 2 avec différentes initialisations de $(\sigma_\rho)_0^i$: trajectoire 1 et SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.

La figure 3.7.9a présente l'évolution de la REQM au cours du temps. Nous présentons également en figure 3.7.9b l'évolution de l'espérance de σ_ρ au cours du temps.

Nous observons qu'indépendamment de l'initialisation de $(\sigma_\rho)_0^i$, les courbes de REQM convergent vers une même erreur avec presque la même vitesse




(a) Évolution de la REQM.



(b) Évolution de $E[\sigma_\rho]$ au cours du temps.

FIGURE 3.7.10 – Filtre particulaire Swerling I/ approche 2 avec différentes initialisations de $(\sigma_\rho)_0^i$: trajectoire 1 et SNR=15 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.



(a) Évolution de la REQM.


(b) Évolution de $E[\sigma_\rho]$ au cours du temps.

FIGURE 3.7.11 – Filtre particulaire Swerling I/ approche 2 avec différentes initialisations de $(\sigma_\rho)_0^i$: trajectoire 2 et SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.


de convergence. De même, les courbes $E[\sigma_\rho]$ elles-mêmes convergent vers une même valeur pour chaque configuration. Nous pouvons conclure que l'initialisation de $(\sigma_\rho)_0^i$ n'a pas d'influence importante sur les performances du filtre particulière et cette stratégie est robuste au choix du paramètre. Nous proposons de tirer aléatoirement les $(\sigma_\rho)_0^i$ par la suite.

Pour comparer ces deux approches du filtre particulière Swerling I et les comparer avec le filtre particulière GLRT, nous traçons les courbes de REQM de ces trois filtres sur la même figure : filtre particulière GLRT ($\sigma_\alpha = 0$), filtre particulière Swerling I avec la première approche ($\sigma_\rho = 0.002$) et avec la deuxième approche ($(\sigma_\rho)_0$ tirés aléatoirement).


Nous constatons que le filtre particulière GLRT fournit généralement de bonnes performances dans tous les cas par rapport aux filtres particuliers Swerling I. Nous observons également que le filtre particulière Swerling I/approche 1 avec un choix sélectif de σ_ρ fournit de meilleures performances que le filtre Swerling I/approche 2. Toutefois, nous devons remarquer que ces performances ne sont pas garanties pour d'autres trajectoires de la cible. Autrement dit, il faut relancer le processus pour le choix de σ_ρ pour chaque trajectoire examinée pour assurer de bonnes performances du filtre, ce qui nécessite un coût de calcul non négligeable. Dans le cas contraire, une valeur σ_ρ qui est optimisée pour une trajectoire peut fournir des performances sous optimales pour une autre trajectoire. Le filtre particulière Swerling I/approche 2 ne nécessite pas de choisir σ_ρ mais conduit à de moins bonnes performances que le filtre particulière GLRT. Le fait qu'il ajoute un autre paramètre inconnu dans l'état de la cible peut expliquer cette dégradation des performances d'estimation lorsqu'un même nombre de particules est utilisé.

3.7.4 Performances des filtres particuliers

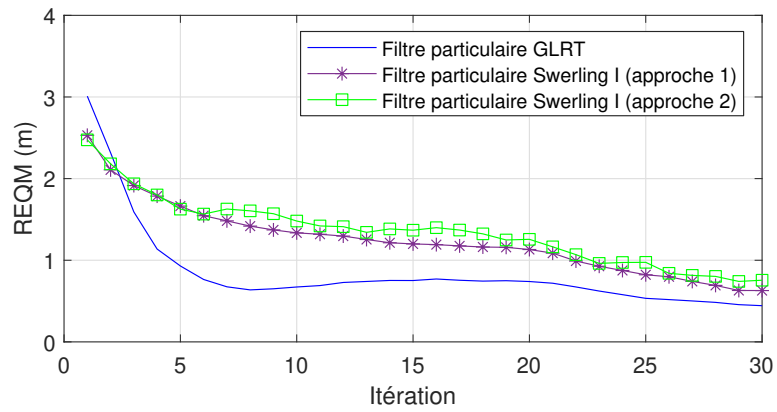
Nous examinons maintenant les performances des filtres avec une moyenne sur différentes trajectoires de la cible. La même simulation que celle présentée dans les paragraphes précédents est effectuée pour d'autres trajectoires aléatoires de la cible dans la zone observée (positions initiales et vitesses de la cible tirées aléatoirement). Nous examinons le filtre particulière GLRT, le filtre particulière Swerling I/approche 1 avec $\sigma_\rho = 0,002$ pour toutes les trajectoires et le filtre particulière Swerling I/approche 2 où les paramètres $(\sigma_\rho)_0^i$ sont tirés aléatoirement à partir d'une distribution uniforme $[0, 001; 0, 02]$. Les REQM fournies par ces filtres sont calculées par simulation de Monte Carlo en moyennant sur toutes les trajectoires et sont présentées en figure 3.7.13a. Au total, nous réalisons 1000 simulations de Monte Carlo : nous tirons aléatoirement 100 trajectoires de la cible ; pour chaque trajectoire nous prenons 10 réalisations de bruit différentes. Dans le premier cas où le SNR de la cible est



(a) Trajectoire 1 / SNR =10 dB




(b) Trajectoire 1 / SNR =15 dB



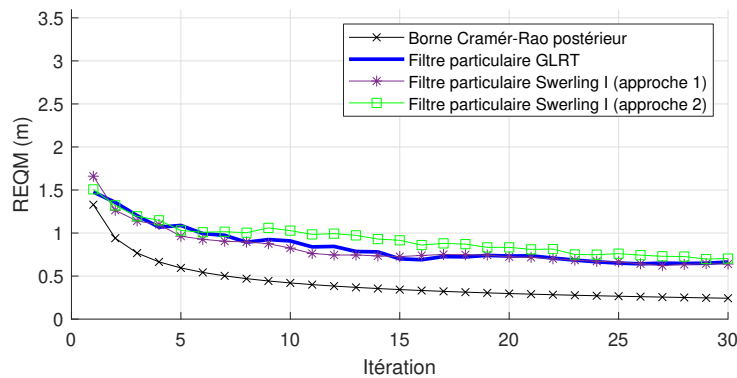
(c) Trajectoire 2 / SNR =10 dB

FIGURE 3.7.12 – Comparaison des performances de différents filtres pour différentes configurations examinées. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.

à 10dB, nous observons que le filtre particulaire GLRT fournit les meilleures performances aussi bien en terme d'erreur quadratique qu'en terme de vitesse de convergence. Les deux approches du filtre particulaire Swerling I fournissent presque la même erreur à la fin des trajectoires mais l'approche 2 fournit une vitesse de convergence bien meilleure que celle de l'approche 1. Ce résultat confirme notre remarque précédente concernant σ_ρ qui doit être sélectionné de manière particulière pour chaque trajectoire ; dans le cas contraire, les performances du filtre peuvent être dégradée. Quand le SNR devient plus élevé (15dB), nous observons en figure 3.7.13b que la courbe du filtre particulaire Swerling I/ approche 1 se rapproche de celle du filtre GLRT.



(a) SNR=10 dB.



(b) SNR=15 dB.

FIGURE 3.7.13 – Performances de différents filtres moyennées sur des trajectoires tirées aléatoirement. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$.


Nous traçons également dans la même figure 3.7.13 la borne de Cramér-Rao a posteriori sur toute la zone observée en suivant les calculs récursifs décrits au

paragraphe 3.6.2. Nous observons que les courbes REQM fournies par les filtres particuliers proposés sont proches de la borne de Cramér-Rao a posteriori, ce qui montre de bonnes performances des algorithmes. Toutefois, il reste un écart entre les courbes de performances des filtres et la borne. Pour voir si le nombre de particules utilisées pour les filtres particuliers pouvait être une explication de cet écart, nous avons augmenté le nombre de particules $N_p = 4800$ (3 fois la valeur utilisée pour les simulations ci-dessus). Nous avons constaté que les nouvelles courbes REQM des filtres restent très proches de celles présentées en figure 3.7.13 obtenues avec $N_p = 1600$. Cet écart à la borne peut sinon être expliqué par la discrétisation de l'espace en cases, la présence de fortes ambiguïtés, ou l'amplitude inconnue des multi-trajets qui doivent être estimées et donc tendent à augmenter la variance d'estimation.


Par ailleurs, bien qu'effectuée classiquement, la comparaison des performances des filtres par rapport à une borne moyennée sur tout l'espace n'est pas toujours pertinente car certaines trajectoires sont plus ou moins favorables aux filtres particuliers. Nous étudions alors les performances des filtres pour une seule trajectoire, comparées à la borne de Cramér-Rao a posteriori conditionnelle à cette trajectoire. La borne conditionnelle est calculée par simulation pour une trajectoire donnée comme indiqué dans [Zuo 11]. A l'itération k , la densité a posteriori est calculée par un filtre particulier, étant donné les mesures $\mathbf{z}_{1:k}$. 1000 simulations de Monte Carlo sont réalisées pour générer 1000 tirages de \mathbf{z}_{k+1} afin de calculer $\text{EQM}(\hat{\mathbf{x}}_{k+1}(\mathbf{z}_{1:k}))$ en suivant les calculs récursifs décrits au paragraphe 3.6.3. A l'itération $k + 1$, un seul tirage de \mathbf{z}_{k+1} est gardé parmi les 1000 tirages et concaténé avec les mesures antérieures pour former $\mathbf{z}_{1:k+1}$. Les particules et les poids correspondant à ce \mathbf{z}_{k+1} particulier sont stockés pour l'itération $k + 1$. Par exemple la figure 3.7.14 montrent les bornes obtenues pour les trajectoires 1 et 2 pour un SNR égal à 10 dB. Nous observons que l'écart entre les courbes REQM des filtres et la borne conditionnelle, qui varie d'une trajectoire à l'autre, reste assez faible dans les deux cas de figure. Nous pouvons donc conclure que les performances des filtres proposés restent relativement proches de l'optimal.

3.8 Conclusion

Nous avons proposé dans ce chapitre deux filtres particuliers pour pister une cible en milieu urbain en présence de multi-trajets. Ces algorithmes prennent en compte la dynamique de la cible pour lever les ambiguïtés de localisation et donc améliorent de manière notable l'estimation de la position de la cible par rapport aux algorithmes de localisation proposés dans le chapitre précédent. Ensuite, nous avons calculé les bornes de Cramér-Rao a posteriori



(a) Trajectoire 1.



(b) Trajectoire 2.

FIGURE 3.7.14 – Performances des filtres pour la trajectoire 1 et 2 de la configuration représentée par la figure 3.7.2 ($N_p = 1600$, $\beta = 1/3$, $N_{MC} = 1000$) par rapport à la borne de Cramér-Rao a posteriori conditionnelle. SNR=10 dB.

conditionnelle et non conditionnelle dans notre cas particulier. Nous avons ensuite comparé les performances des filtres entre eux et avec les bornes. Nous observons que le filtre particulaire GLRT fournit de meilleures performances que le filtre particulaire Swerling I en terme de vitesse de convergence et d'erreur de convergence. La comparaison aux bornes de Cramér-Rao a posteriori illustre les bonnes performances des algorithmes proposés en terme d'erreur quadratique. Nous avons également observé que le calcul du filtre GLRT est plus rapide que celui du filtre Swerling I pour un nombre de particules identique.

Chapitre 4

Expérimentation et application des algorithmes sur données réelles

Dans ce chapitre, nous présentons d'abord dans la section 4.1 une description du radar et du scénario expérimental, représentatif d'une intersection urbaine. Ensuite, dans la section 4.2, nous interprétons les mesures pour déterminer si les multi-trajets sont mesurables et bien présents dans les données obtenues. Dans la section 4.3, nous appliquons les algorithmes de détection et localisation FMU et SLC aux données mesurées et analysons les résultats. Enfin, les algorithmes de pistage développés au chapitre 3 comme les filtres particuliers GLRT et Swerling I sont appliqués aux données et leurs performances de localisation sont comparées avec celles de l'algorithme FMU sans pistage.

4.1 Description de l'expérimentation

4.1.1 Description du radar

Pour les expérimentations, nous avons utilisé un petit radar commercial émettant à 24 GHz (figure 4.1.1). Notons que ce radar n'a pas initialement été développé pour notre application. Le signal transmis consistait en un train cohérent d'impulsions LFM. La bande passante était de 800 MHz, ce qui correspond à une résolution distance de 0,1875 m. Une largeur de bande assez importante a été nécessaire pour pouvoir résoudre les multi-trajets proches. La durée de chaque impulsion était de 8 ms, et la période de répétition d'impulsion était de 60 ms. Cette très longue période de répétition d'impulsion, en raison de la configuration matérielle spécifique du radar (non dédiée à notre application particulière), fournit une très petite vitesse ambiguë (environ 0,1 m/s). Le radar a été placé à une hauteur de 1,2 m au dessus du sol, l'ouverture

angulaire du radar était de 60° . Un filtre adapté distance est intégré dans le radar et automatiquement appliqué en sortie du radar, de sorte que les données disponibles pour le traitement sont uniquement les données obtenues en sortie de compression distance. Les paramètres du radar utilisé sont rappelés au tableau récapitulatif 4.1.

Fréquence porteuse	24 GHz
Bande passante	800 MHz
Durée d'impulsion	8 ms
Période de répétition	60 ms
Durée de l'enregistrement	15 s
Ouverture angulaire (azimut)	60°
Ouverture élévation	25°

TABLE 4.1 – Paramètres du radar utilisé.



FIGURE 4.1.1 – Radar utilisé pour les expérimentations (IMST 24 GHz 2-Channel FMCW Radar). Source : www.imst.com.

4.1.2 Description du scénario

L'expérimentation a eu lieu sur le site de l'école CentraleSupélec à Gif-sur-Yvette. Une jonction représentative d'une intersection urbaine a été sélectionnée pour la campagne de mesure réelle (figure 4.1.2). Un schéma représentatif est présenté en figure 4.1.5, avec le système de coordonnées utilisé pour la suite. Le radar est placé aux coordonnées (6, 8; 0). Il est connecté à un PC portable pour enregistrer les données mesurées par l'intermédiaire d'un Raspberry Pi

(figure 4.1.3). Nous avons choisi le scénario où une cible piétonne marche de $D(15, 5; 12, 75)$ à $C(15, 5; 24, 75)$ pendant 15 secondes. Au début de sa trajectoire, la cible piétonne est en NLOS. De la position $y_c = 18$ jusqu'à C, la cible est en LOS, mais des multi-trajets sont toujours présents. Le piéton porte une couverture de survie dans le but d'améliorer la réflexion des ondes électromagnétiques sur la cible (figure 4.1.4). Une simulation de tracé de rayons est présentée en figure 4.1.5 pour montrer visuellement des multi-trajets pour une position spécifique de la cible.




FIGURE 4.1.2 – Scénario des mesures réelles : le radar a été placé à l'extrémité du tunnel (cercle bleu). La cible (piéton) se déplaçait dans la section droite de la jonction (rectangle rose).




FIGURE 4.1.3 – Configuration des dispositifs de mesure.



FIGURE 4.1.4 – Photo d'un piéton considéré comme cible en déplacement.

4.2 Interprétation des mesures

La sortie du filtre adapté en distance avant la réjection des échos fixes pour les 15 secondes est présentée en figure 4.2.2. Il apparaît que les échos fixes sont forts et cachent les échos de la cible, ce qui motive la procédure de réjection zéro-Doppler expliquée dans le paragraphe 1.2.2 du chapitre 1. Après la réjection des échos fixes à Doppler nul, notons qu'à cause de l'ambiguïté Doppler très petite (environ 0,1 m/s), tous les échos Doppler non nuls sont donc répartis sur tout le domaine Doppler, ce qui est visible en figure 4.2.1. Le traitement a consisté ici à intégrer de façon incohérente l'énergie de toutes les cases Doppler non nulles pour chaque case distance. Les profils distance obtenus en sortie de ces traitements sont présentés en figure 4.2.3. Dans la zone NLOS, les profils distance ne contiennent que des échos dus à des trajets réfléchis au moins par un mur. Dans la zone LOS, l'écho fort le plus proche résulte du trajet direct réfléchi par la cible (sans réflexion sur les murs environnants).

Afin d'interpréter les échos observés dans la mesure, une simulation a été réalisée avec un modèle géométrique approximatif de la scène réelle (en particulier les portes, fenêtres et autres éléments présents dans la scène n'ont pas été modélisés) en utilisant un simple simulateur de tracé de rayons (voir Figure 4.2.4).

En comparant le résultat de la simulation en Figure 4.2.4 et de la mesure en Figure 4.2.3, nous observons un très bon accord entre les échos générés par la simulation et les échos observés sur la mesure réelle. Dans la zone NLOS (les




FIGURE 4.1.5 – Schéma représentatif du scénario : les segments verts correspondent à des échos fixes, les segments bleus et rouges représentent respectivement des trajectoires radar-cible avec des réflexions à un et deux rebonds.

8 premières secondes), les trois premiers échos les plus forts indiqués par 1, 2 et 3 sont bien simulés par le tracé de rayons. La différence d'énergie observée entre les échos en Figure 4.2.3 peut s'expliquer par les coefficients de réflexion des différents murs, la perte due aux différents angles d'arrivée et la perte en dehors du lobe principal du radar.

Dans la zone LOS (après 8 s), le trajet direct est clairement observé, ce qui est cohérent avec l'écho rouge de la simulation. Cependant, certains échos peuvent être observés en Figure 4.2.3, qui ne sont pas expliqués par le résultat de la Figure 4.2.4. Ces échos sont moins énergétiques et parallèles au premier




FIGURE 4.2.1 – Réponse Doppler à un instant donné.




FIGURE 4.2.2 – Profils distance avant filtrage zéro-Doppler pour le scénario décrit en paragraphe 4.1.2.




FIGURE 4.2.3 – Profils distance après filtrage zéro-Doppler pour le scénario décrit en paragraphe 4.1.2.

écho dans la zone LOS. L'explication la plus probable est la simplicité de la géométrie approximative utilisée dans la simulation. En fait, un modèle 2D est utilisé pour la simulation mais en réalité le plafond du tunnel pourrait peut-être être la source des autres multi-trajets, atténués en raison d'un diagramme d'antennes plus étroit dans la direction verticale.




FIGURE 4.2.4 – Profils distance simulés. Écho rouge, orange, vert, bleu ciel et bleu marine : trajets avec zéro, une, deux, trois et quatre réflexions sur les murs respectivement.

4.3 Détection et localisation sur les données réelles

4.3.1 Données et pré-traitement

Les données obtenues du radar sont les signaux sortis du filtre adapté intégré directement dans le radar. Toutefois, comme évoqué précédemment, ces signaux présentent des échos fixes très forts comme montré en figure 4.2.2, les échos multi-trajets de la cible sont cachés et presque invisibles. Il est donc nécessaire d'appliquer un filtre zéro Doppler, par exemple, par une projection orthogonale présentée en paragraphe 1.2.2 du chapitre 1. Nous pouvons désormais exploiter les informations des multi-trajets pour les tests de détection et localisation FMU et SLC. Sur toute la trajectoire de la cible, nous nous intéressons aux 79 instants de la cible dans la zone NLOS : de la position $(15, 5; 14, 575)$ jusqu'à la position $(15, 5; 17, 695)$. Chaque instant correspond à un signal complexe qui est considéré comme le signal mesuré \mathbf{z} décrit dans les algorithmes. L'intervalle de temps entre deux instants est d'environ 0,06 s. Notons que pour appliquer les tests de détection et les algorithmes de pistage, les signaux utilisés ne doivent pas être considérés après l'intégration d'énergie décrite en section 4.2 pour nous assurer que l'hypothèse du bruit gaussien est valable. Pour les tests de localisation, nous allons regarder et comparer l'application sur les données avant et après intégration d'énergie.

Les deux algorithmes de détection et localisation présents dans le chapitre

2 comprennent une étape de discrétisation de l'espace : la zone observée est divisée en petites cases de taille 0,1875 m x 0,1875 m. Cette taille est choisie égale à la résolution distance du radar.

Les vraies positions de la cible utilisées par la suite pour évaluer les performances des algorithmes sont estimées par une interpolation linéaire à partir de la position de démarrage, la position de fin et le temps de trajet de la cible en supposant que sa vitesse est constante tout le long de sa trajectoire.

4.3.2 Test de détection-localisation

Les algorithmes FMU et SLC sont appliqués aux données réelles avant l'intégration d'énergie présentées ci-dessus. Nous présentons en figure 4.3.1 et 4.3.2 respectivement la sortie des tests T_{FMU} et T_{SLC} pour toutes les cases dans la zone considérée. Pour le problème de localisation, nous observons que dans tous les exemples la position estimée par le maximum des tests FMU et SLC $(\hat{x}, \hat{y}) = \arg \max (T(x, y))$ est très proche de la vraie position de la cible. La racine de l'erreur quadratique entre la position estimée et la vraie position dans la plupart des cas reste inférieure à 0,5 m. Cependant, comme constaté dans le paragraphe précédent, nous observons de forts niveaux des ambiguïtés. Nous remarquons que les ambiguïtés représentent les arcs de cercle qui correspondent aux retards de différents multi-trajets.

Nous présentons en figure 4.3.3a et b respectivement les sorties des tests FMU et SLC appliqués aux signaux mesurés quand le piéton est localisé aux coordonnées (15, 5; 16, 2) et en figure 4.3.3c la sortie du test FMU appliqué aux données obtenues par une simulation sur un modèle géométrique simplifié de la scène. Notons que ce modèle ne prend en compte que les positions des murs, aucune information sur la permittivité des matériaux réfléchissants ni la modélisation de détails fins tels que des portes ou des fenêtres, et un modèle simple de tracé de rayons pour la propagation. Nous observons malgré tout un bon accord entre les ambiguïtés de (a), (b) et (c), au moins en terme de géométrie, les amplitudes n'ayant pas été modélisées vraisemblablement. Ces ambiguïtés sont dues à la géométrie de la scène et seront donc très vraisemblablement présentes avec toute méthode exploitant la géométrie.

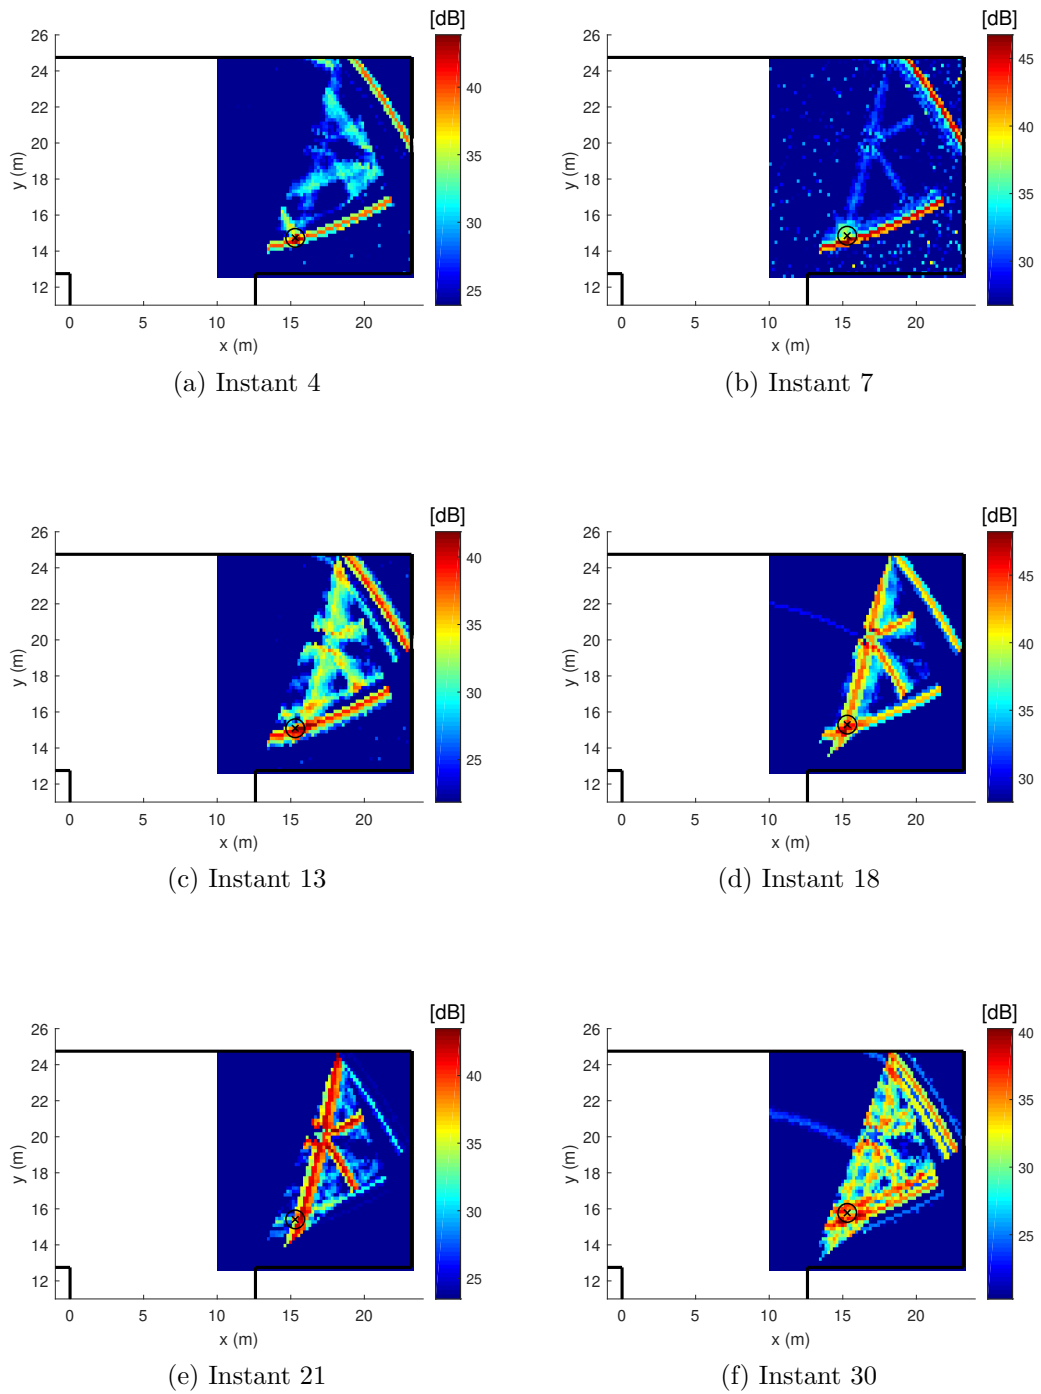


FIGURE 4.3.1 – Exemples de localisation par l’algorithme FMU sur les données expérimentales du scénario de la figure 4.1.5. La vraie position de la cible est représentée par le cercle noir.

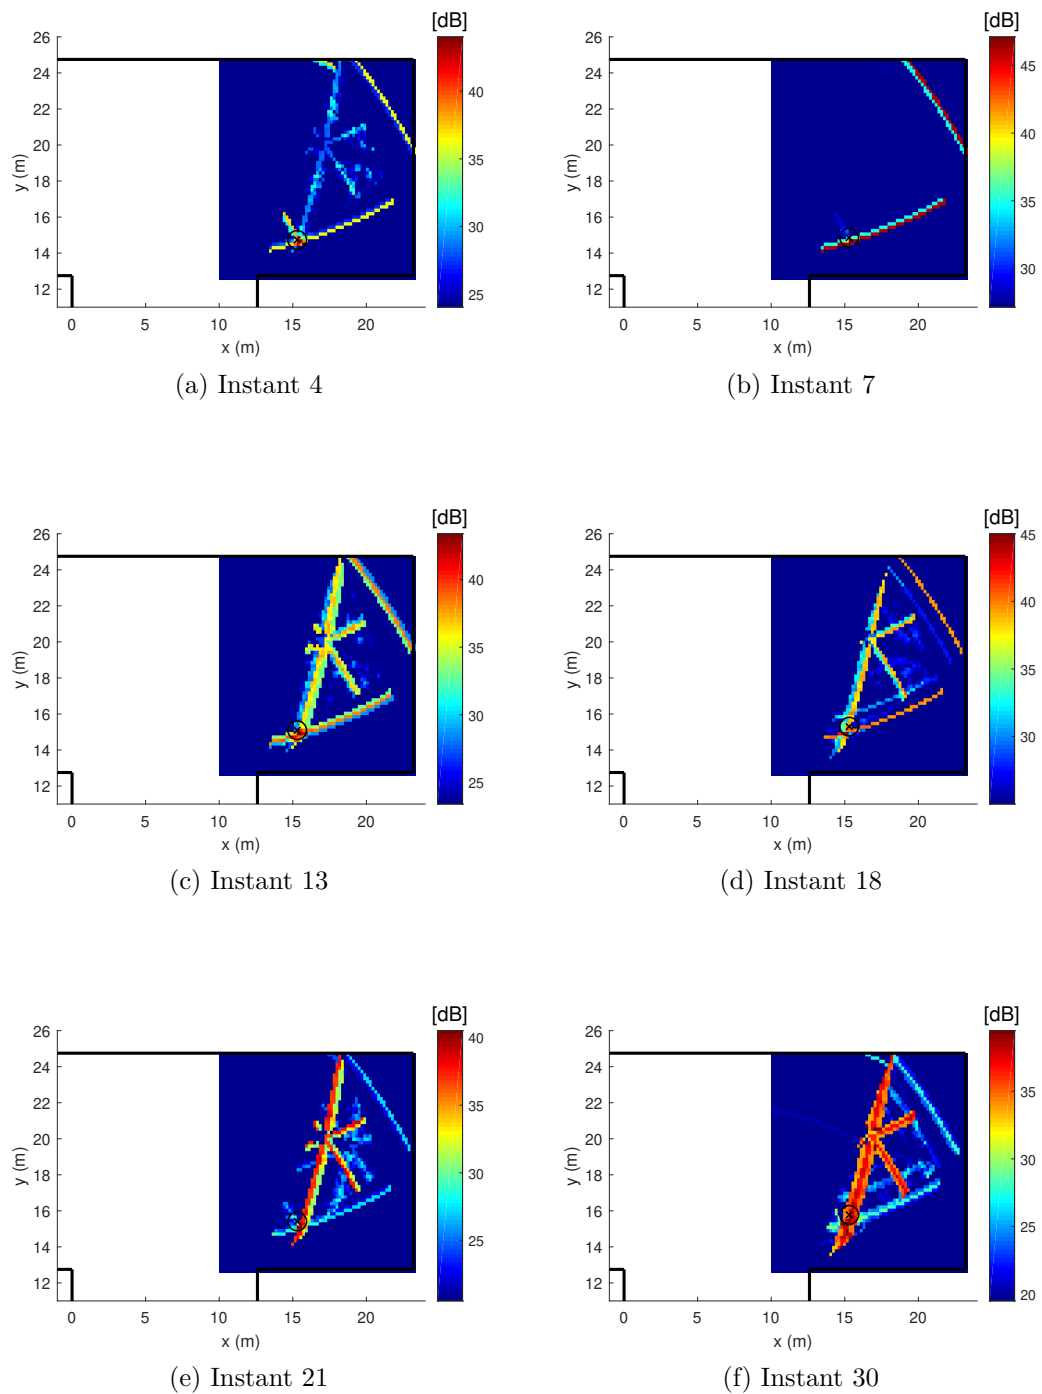





FIGURE 4.3.2 – Exemples de localisation par l’algorithme SLC sur les données expérimentales du scénario de la figure 4.1.5. La vraie position de la cible est représentée par le cercle noir.



(a) Résultat de la localisation sur le signal mesuré : sortie du test FMU



(b) Résultat de la localisation sur le signal mesuré : sortie du test SLC



(c) Résultat de la localisation sur le signal obtenu par simulation (tracé de rayons)

FIGURE 4.3.3 – Localisation de la cible située en position (15, 5; 16, 2).

Ces ambiguïtés sont susceptibles de créer des fausses localisations. Nous montrons quelques exemples où la cible est localisée à un mauvais endroit à cause de ces ambiguïtés en figure 4.3.4. Malgré un niveau élevé du test FMU observé à la case correspondant à la vraie position de la cible (cercle noir), le maximum du test (cercle vert) est localisé très loin de cette position.




FIGURE 4.3.4 – Exemples de l’erreur de localisation par l’algorithme FMU à cause des ambiguïtés. La vraie position de la cible est représentée par le cercle noir. La position estimée est indiquée par le cercle vert.

Nous traçons en figure 4.3.5 la racine de l’erreur quadratique (REQ) entre la position estimée et la vraie position de la cible pour tous les instants le long de la trajectoire de la cible pour les algorithmes de FMU et SLC.

Le taux de bonne localisation pour une REQ de moins de 0,75 m est égal à 49,37% pour l’algorithme FMU. Ce taux est égal à 64,56% pour l’algorithme SLC. Nous constatons donc ici que l’algorithme SLC fournit une performance de localisation meilleure que celle de l’algorithme FMU. Nous observons que




FIGURE 4.3.5 – Erreur de localisation le long de la trajectoire cible.

cela est essentiellement dû à la création d'un nombre plus important d'ambiguïtés pour l'algorithme FMU ou à des ambiguïtés de niveau plus élevé. D'ailleurs, ces deux algorithmes présentent un niveau assez élevé de fausses localisations, notamment à partir du milieu de la trajectoire. Ces erreurs peuvent être expliquées par des ambiguïtés présentes dans un contexte où le niveau du bruit environnant est élevé. Autrement dit, le radar utilisé n'a pas fourni assez d'énergie pour l'application. Nous avons essayé de contourner cette limite en appliquant le traitement de l'intégration non cohérente présenté dans la section 4.2 pour collecter plus d'énergie des multi-trajets par rapport au bruit environnant. Pour rappel, ce traitement consiste à intégrer de façon incohérente l'énergie de toutes les cases Doppler non nulles pour chaque case distance. La figure 4.3.6 montre la REQ de la localisation le long de la trajectoire de la cible en appliquant ces deux algorithmes à ces nouvelles données. Le taux de localisation avec la REQ de moins de 0,75 m est de 89% pour l'algorithme FMU. Ce taux est de 82% pour l'algorithme SLC. Nous observons une amélioration significative par rapport aux résultats précédents. Toutefois, des fausses localisations sont toujours présentes.

En ce qui concerne la détection, comme expliqué ci-dessus, nous n'avons travaillé qu'avec les données avant intégration d'énergie pour nous assurer que l'hypothèse du bruit gaussien est valable. La détection est obtenue par un seuillage de la sortie des test FMU et SLC. Le seuil de détection est calculé par l'équation (2.15) pour toutes les cases de zone observée pour différentes probabilités de fausse alarme $P_{FA} = 10^{-3}$, $P_{FA} = 10^{-4}$, $P_{FA} = 10^{-5}$ respectivement. La variance du bruit σ^2 est calculée à partir de mesures sans cible en supposant que le bruit environnant ne varie pas beaucoup au cours d'un petit intervalle de temps. Les résultats de la détection sont montrés en tableau 4.2. De manière générale, pour la trajectoire examinée l'algorithme SLC présente une performance de détection plus faible que celle de l'algorithme

FMU, ce qui est cohérent de la démonstration faite au paragraphe 2.3.5.1. Nous concluons ici que les algorithmes de détection FMU et SLC fonctionnent bien sur les données réelles malgré le peu de connaissances a priori (seulement une connaissance grossière de la géométrie de la scène). Ils arrivent à exploiter les multi-trajets pour détecter la présence de la cible la plupart du temps.

	FMU	SLC
Taux de détection pour $P_{FA} = 10^{-3}$	100%	100%
Taux de détection pour $P_{FA} = 10^{-5}$	100%	96,2%
Taux de détection pour $P_{FA} = 10^{-7}$	98,7%	92,41%
Taux de localisation (pour moins de 0,75 m d'erreur)	49,37%	64,56%
Taux de localisation après intégration de l'énergie sur 8 périodes	89%	82%

TABLE 4.2 – Tableau récapitulatif des performances de détection et localisation des algorithmes FMU et SLC.

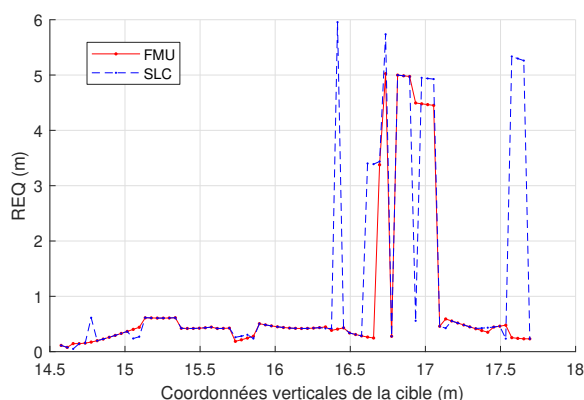


FIGURE 4.3.6 – Erreur de localisation le long de la trajectoire cible des algorithmes FMU et SLC sur les signaux après traitement d'intégration Doppler.

4.4 Pistage sur les données réelles

4.4.1 Filtre particulaire GLRT

Le filtre particulaire GLRT est appliqué aux données réelles en suivant le cadre de l'algorithme 2 décrit en chapitre 3 avec $N_p = 4615$ particules, nombre qui correspond au nombre de cases discrétisées de l'espace. Le résultat obtenu avec ce filtre est présenté en figure 4.4.1.

Nous observons que le filtre particulaire fournit une performance de localisation bien meilleure que celle de l'algorithme FMU. Une fois la convergence du filtre atteinte, la REQ reste toujours inférieure à un mètre. Autrement dit, le filtre particulaire GLRT a réussi à alléger les ambiguïtés typiques du problème du radar en milieu urbain pour diminuer les fausses localisations. Pour illustrer la convergence du filtre ainsi que la diminution des ambiguïtés, nous présentons en figures 4.4.2 et 4.4.3 la sortie du test FMU et les poids des particules du filtre particulaire GLRT pour les premières itérations.




FIGURE 4.4.1 – Erreur de localisation le long de la trajectoire cible du filtre particulaire GLRT et de l'algorithme FMU.

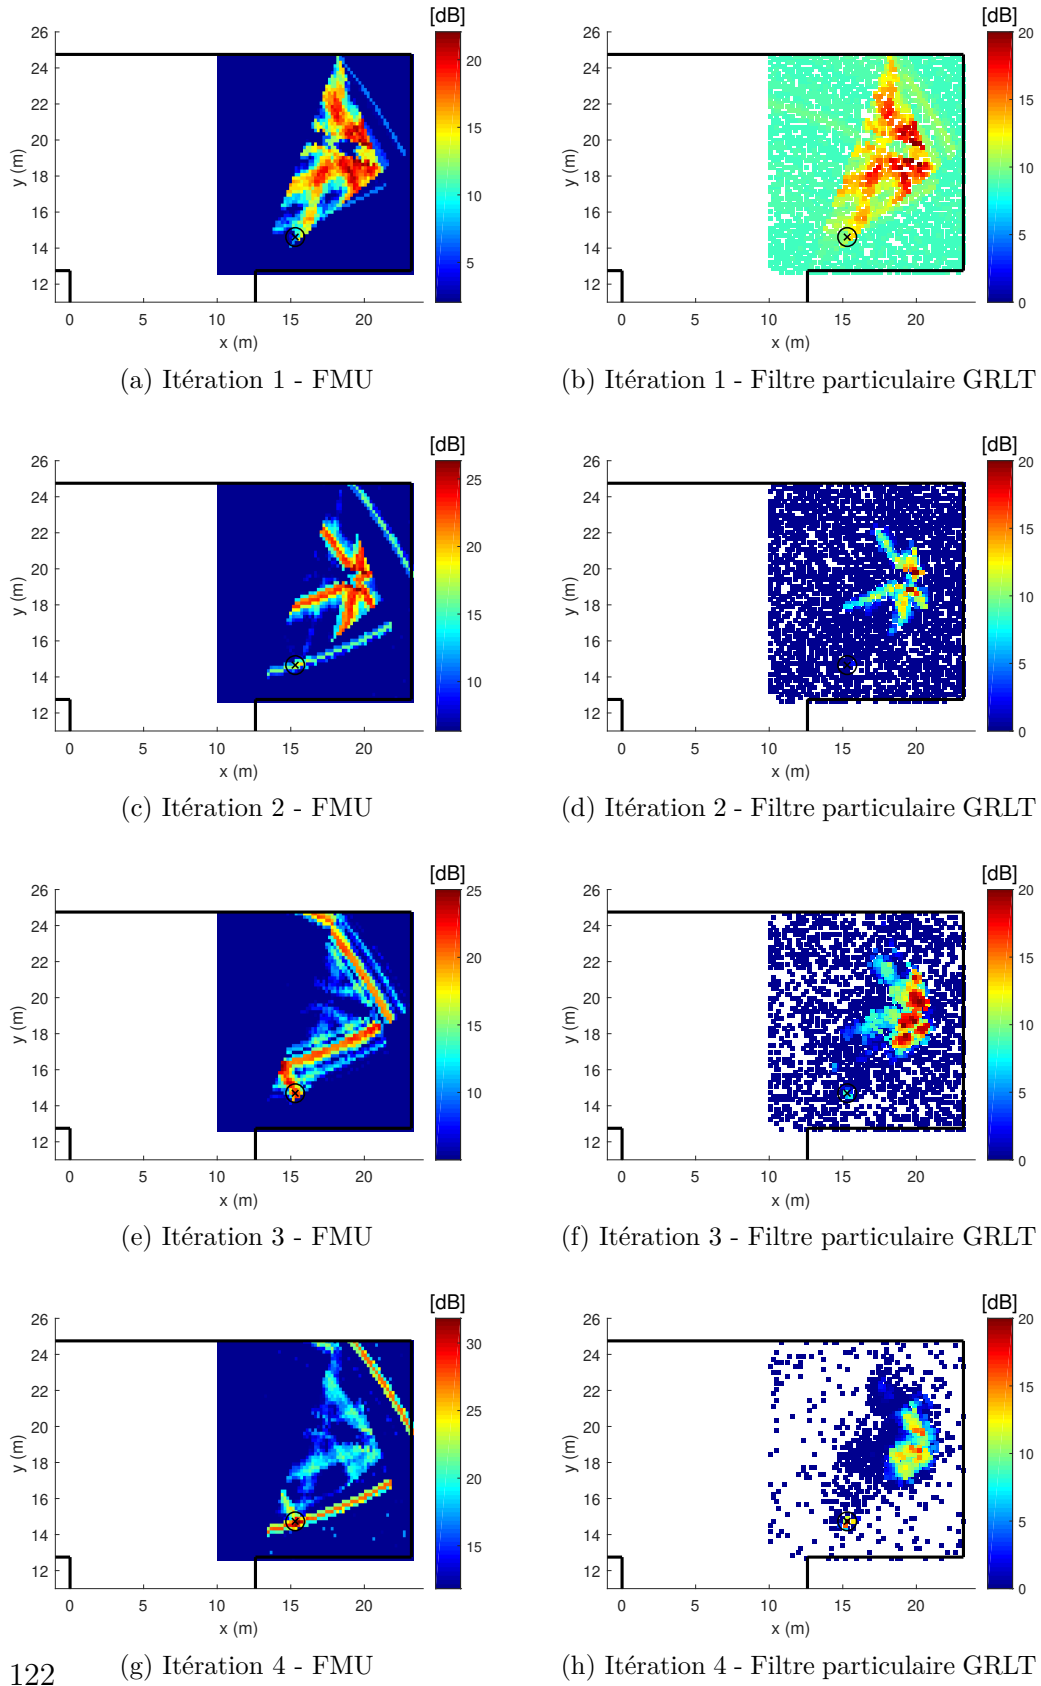


FIGURE 4.4.2 – Sortie du test de localisation FMU et les particules du filtre particulaire GLRT (itérations 1-4).

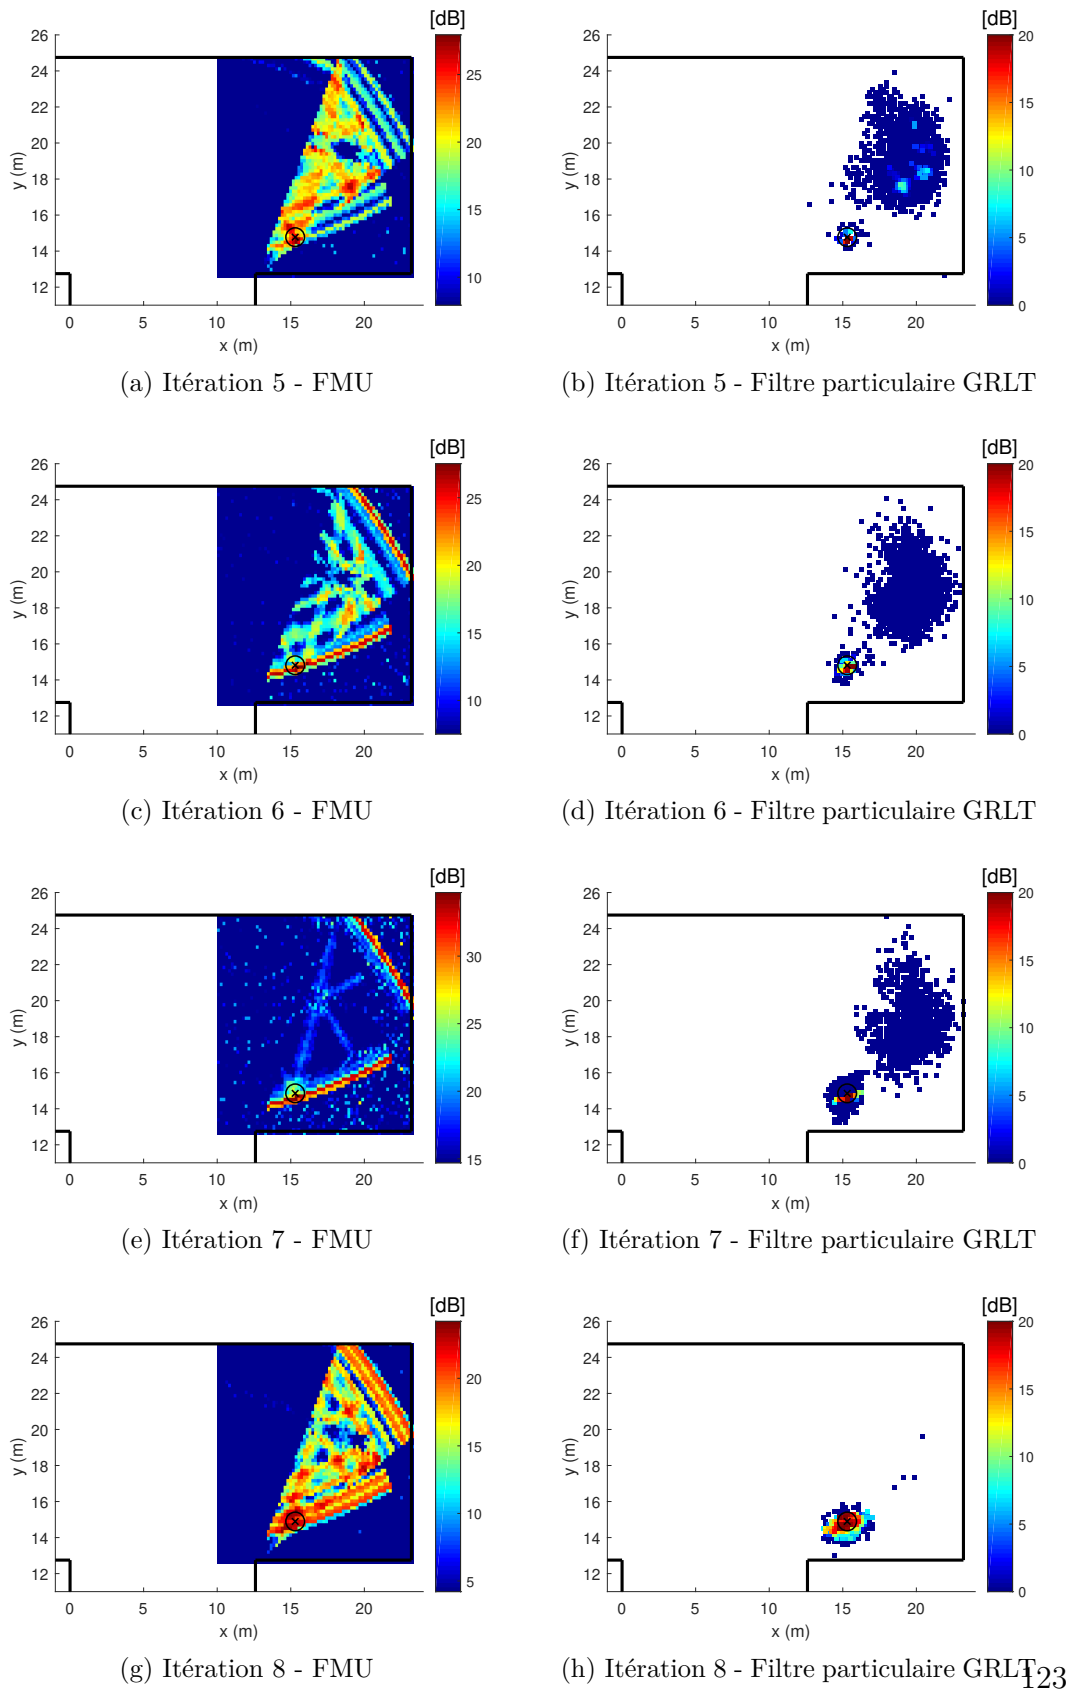


FIGURE 4.4.3 – Sortie du test de localisation FMU et les poids des particules du filtre particulaire GLRT (itérations 5-8).

Nous remarquons que le cas de figure ci-dessus est assez favorable au filtre particulaire car le début de la trajectoire de la cible ne présente pas autant de fortes ambiguïtés causant beaucoup de fausses localisations que celles présentées à la fin de la trajectoire. Cette situation favorise la convergence du filtre particulaire. Il nous paraît naturel de vouloir tester le filtre particulaire dans le contexte de fortes ambiguïtés au début de la trajectoire pour voir si le filtre arrive à converger malgré toutes ces ambiguïtés. En supposant que les signaux mesurés ne dépendent que de la position du piéton et pas de son sens de marche, nous pouvons considérer le problème de la cible marchant en sens inverse avec les mêmes données : de la position (15, 5; 17, 695) jusqu'à la position (15, 5; 14, 575). La figure 4.4.4 montre le résultat du pistage par filtre particulaire GLRT pour ce scénario. Nous observons que malgré les fortes ambiguïtés causant des fausses localisations pour l'algorithme FMU au début de la trajectoire, le filtre GLRT converge aussi rapidement et fournit de bonnes performances de localisation tout le long de la trajectoire de la cible. Nous fournissons en figures 4.4.5 et 4.4.6 la sortie du test FMU et les poids des particules du filtre particulaire GLRT pour les premières itérations.

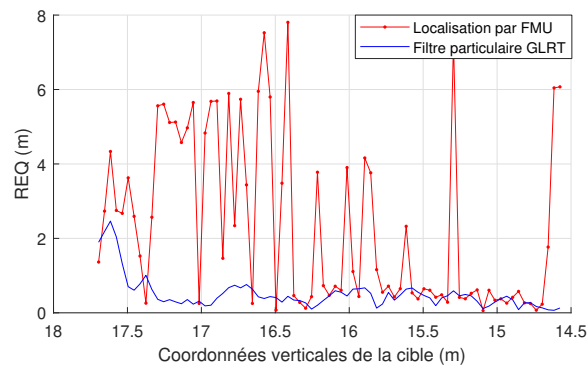


FIGURE 4.4.4 – Erreur de localisation le long de la trajectoire en sens inverse de la cible.

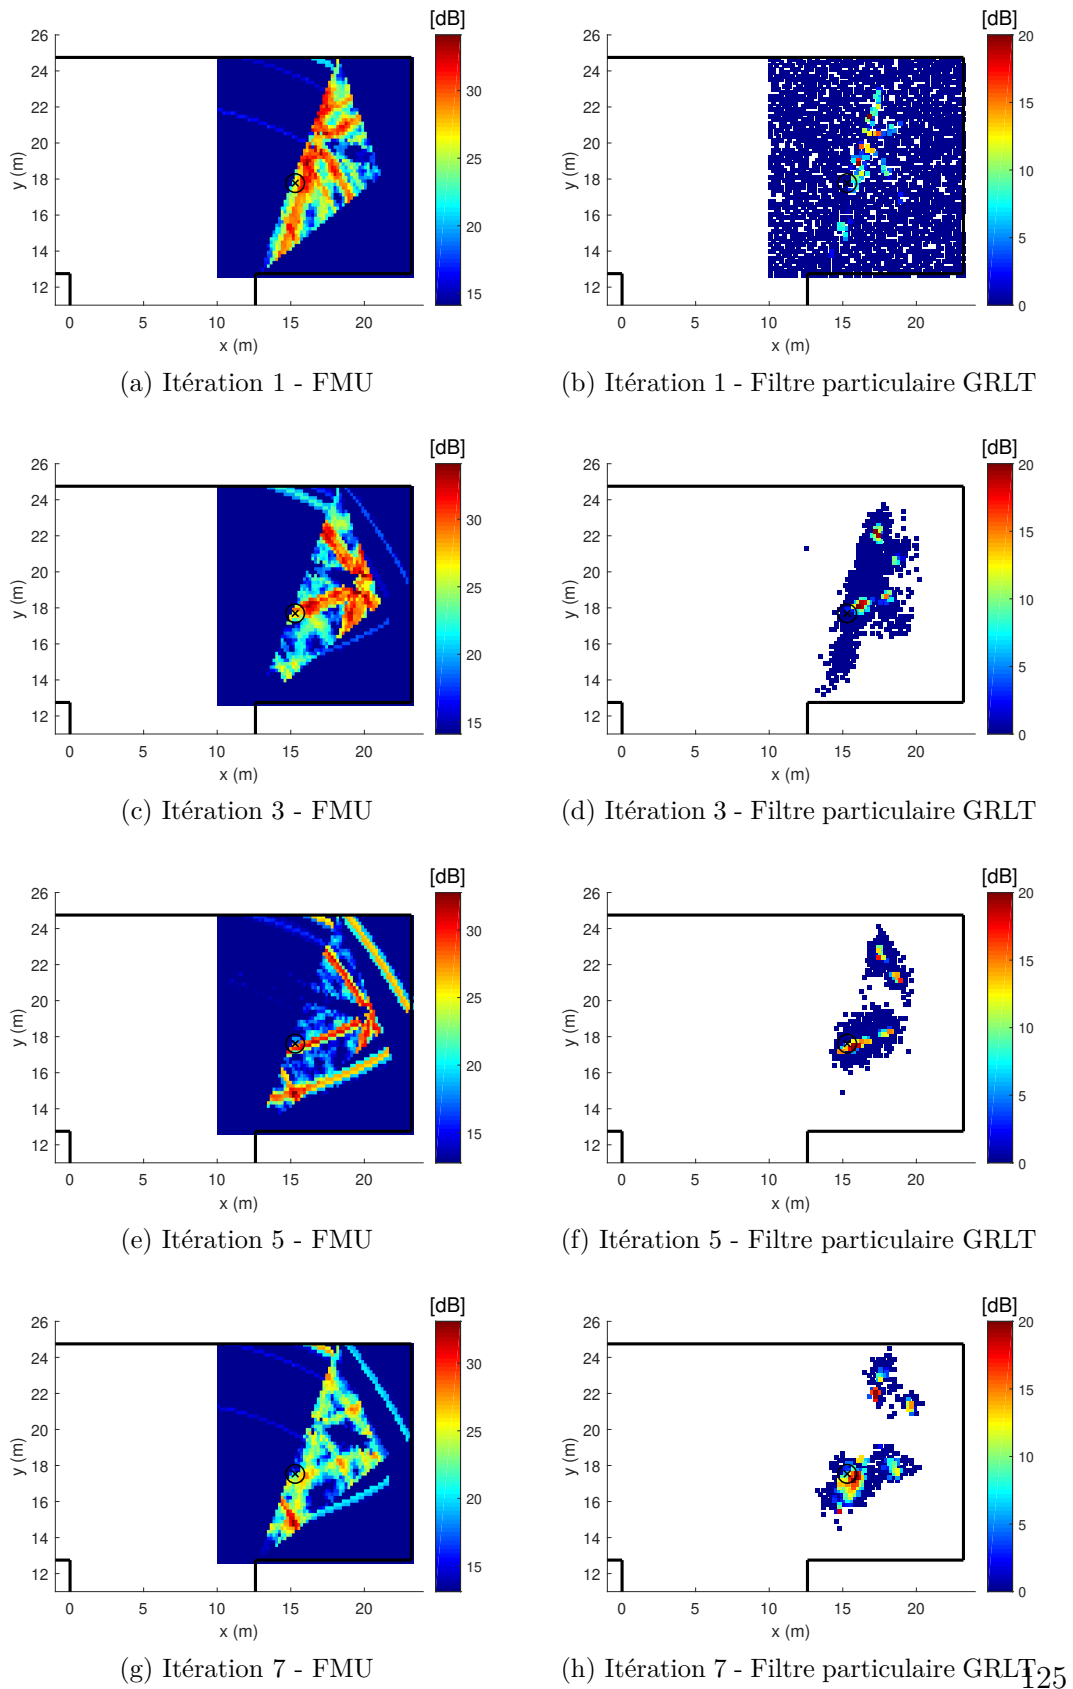


FIGURE 4.4.5 – Sortie du test de localisation FMU et les particules du filtre particulaire GLRT pour la trajectoire en sens inverse de la cible (itérations 1-7).




FIGURE 4.4.6 – Sortie du test de localisation FMU et les particules du filtre particulaire GLRT pour la trajectoire en sens inverse de la cible (itérations 9-15).

4.4.2 Filtre particulaire Swerling I

En suivant le cadre du filtre particulaire Swerling I / approche 1 décrit par les algorithmes 3, nous obtenons les résultats présentés en figure 4.4.7 pour différentes valeurs du paramètre σ_ρ . Nous observons que le filtre avec $\sigma_\rho = 0,005$ fournit les meilleures performances en terme de temps de convergence ainsi que d'erreur quadratique tout le long de la trajectoire de la cible. Il apparaît qu'avec des petites valeurs de σ_ρ , le filtre peut présenter des erreurs de localisation dans la zone avec beaucoup d'ambiguïtés (entre 17 et 17,5 m) mais converge à nouveau après quelques itérations.

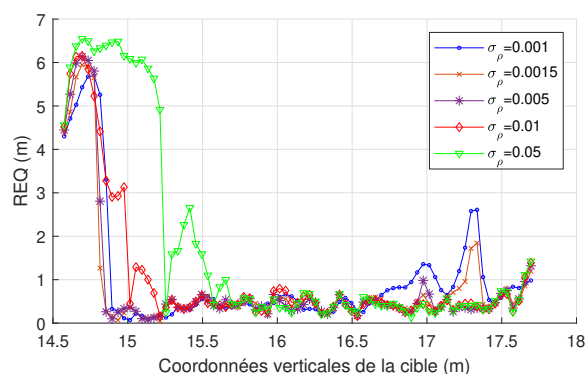


FIGURE 4.4.7 – Résultats du filtre particulaire Swerling I avec approche I pour différentes valeurs du paramètre σ_ρ .

A la figure 4.4.8, nous présentons le résultat du filtre particulaire Swerling I / approche 1 avec la valeur du paramètre retenue $\sigma_\rho = 0,005$ et celui du filtre particulaire Swerling I / approche 2 décrit par l'algorithme 4. Nous observons presque la même vitesse de convergence pour les deux approches du filtre Swerling I que celle du filtre GLRT. Les performances de localisation le long de la trajectoire sont similaires à celles du filtre particulaire GLRT.

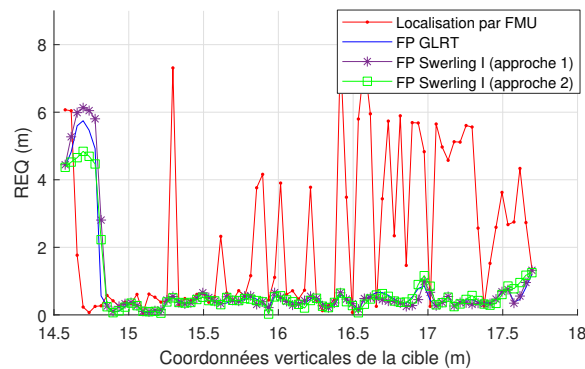


FIGURE 4.4.8 – Erreur de localisation le long de la trajectoire de la cible pour les différents filtres particulaires.

De la même manière, en supposant que la cible se déplace en sens inverse de la position (15, 5; 17, 695) jusqu'à la position (15, 5; 14, 575), les performances fournies par le filtre particulaire Swerling I sont aussi bonnes que celles du filtre particulaire GLRT, comme montré en figure 4.4.9.




FIGURE 4.4.9 – Erreur de localisation le long de la trajectoire en sens inverse de la cible pour différents filtres particulaires.

4.5 Conclusion

Dans ce chapitre, nous avons appliqué les algorithmes de détection, de localisation et de pistage développés aux cours des chapitres précédents aux données réelles mesurées dans une configuration représentative d'une intersection urbaine. Les résultats obtenus permettent de valider notre modèle de propagation multi-trajets en milieu urbain et notamment de montrer qu'il est possible de détecter et retrouver la position de la cible même avec une connaissance approximative de la géométrie de la scène (portes, fenêtres et autres éléments ne

sont pas modélisés) à partir de la seule information portée par les retards des multi-trajets. Cependant, il apparaît que le problème de détection et localisation conduit intrinsèquement à de fortes ambiguïtés spatiales. Une solution considérée pour lever ces ambiguïtés spatiales est d'exploiter le mouvement de la cible au fil du temps avec un algorithme de pistage. Nous avons appliqué les filtres particulière GLRT et Swerling I développés au cours du chapitre 3 aux mêmes données et obtenu effectivement une diminution des ambiguïtés et donc amélioré les performances de localisation sur les données expérimentales. Nous démontrons ici le bien-fondé des approches proposées et développées dans les chapitres précédents.

Conclusion et perspectives

Bilan des travaux effectués

Au cours de cette thèse, nous avons proposé dans un premier temps deux solutions pour la détection et la localisation de la cible en exploitant les multi-trajets : l'algorithme FMU qui est basé sur une projection sur le sous-espace des multi-trajets et l'algorithme SLC qui est basé sur une intégration non cohérente de l'énergie des multi-trajets. Les apports principaux de ce premier axe d'études sont les suivants :

- Pour le problème de détection, nous avons observé que les algorithmes FMU et SLC proposés fournissent généralement de meilleures performances que le filtre adapté classique dans un scénario urbain NLOS typique. En particulier, nous avons montré que l'exploitation par trajets multiples peut améliorer les performances de détection tant que le SNR des trajets supplémentaires est suffisant. Une preuve analytique asymptotique (à fort SNR) est donnée.
- Nous avons également développé un algorithme spécifique pour sélectionner le nombre de multi-trajets, ce qui nous permet d'améliorer les performances de détection en optimisant la probabilité de détection.
- Pour le problème de localisation, les résultats obtenus par simulation montrent que les localisations cibles peuvent être estimées avec succès avec les deux algorithmes même en utilisant un modèle de propagation simple et une connaissance approximative de la géométrie de la scène.
- Nous avons proposé trois corrections du test FMU pour diminuer ces ambiguïtés en appliquant les pénalisations classiques issues des problèmes de sélection de modèle de type BIC et AIC, ainsi que la pénalisation FIC spécifiquement développée pour notre problème. Il ressort que les performances de localisation sont améliorées par ces corrections.
- L'application des algorithmes FMU et SLC aux données réelles montrent qu'il est possible de détecter et localiser une cible dans une scène typique du milieu urbain, même avec une connaissance approximative de la géométrie de la scène (portes, fenêtres et autres éléments ne sont pas

modélisés).

Cependant, nous pouvons citer certaines limites :

- Il apparaît que les solutions de localisation FMU et SLC proposées conduisent à de fortes ambiguïtés spatiales. Ceci est dû à la géométrie de la scène et à la méconnaissance des amplitudes : de nombreuses positions différentes peuvent créer des trajets présentant des temps de retards similaires à ceux d'autres trajets créés par d'autres positions. Une autre raison est potentiellement que seule l'information des retards des multi-trajets est exploitée ici. Notons que cette limitation correspond à une contrainte imposée par le matériel dont nous disposons : les informations Doppler et angulaires des multi-trajets n'ont pas pu être exploitées.
- Les pénalisations BIC, AIC et FIC proposées ne permettent pas de résoudre toutes les ambiguïtés, ni de les éliminer totalement, de sorte que la probabilité de fausse localisation reste non négligeable pour certaines positions.

Le deuxième axe d'études a consisté à développer deux filtres particuliers (GLRT et Swerling I) pour pister une cible en milieu urbain en présence de multi-trajets :

- Il a été montré par simulation que ces algorithmes, qui prennent en compte la dynamique de la cible pour lever les ambiguïtés, améliorent l'estimation de la position de la cible par rapport aux algorithmes de localisation proposés dans le chapitre précédent.
- Ces algorithmes sont appliqués aux données réelles : les résultats obtenus montrent que les filtres particuliers proposés permettent également d'améliorer les performances de localisation.
- Les bornes de Cramér-Rao a posteriori conditionnelle et non conditionnelle ont également été calculées pour notre cas particulier. Il ressort que les performances des filtres particuliers proposés s'approchent de celles des bornes.

Cependant, il s'avère qu'il existe un écart entre les courbes de performances des filtres et les bornes de Cramér-Rao a posteriori. Il y a potentiellement plusieurs raisons parmi lesquelles nous pouvons citer : la présence de fortes ambiguïtés, la discrétisation de l'espace en cases, ou les amplitudes inconnues des multi-trajets qui doivent être estimées et donc tendent à augmenter la variance d'estimation.

Perspectives

Compte tenu du bilan effectué ci-dessus, nous pouvons citer plusieurs perspectives possibles à l'issue de ce travail de thèse :

-
- La prise en compte d'informations autres que les retards comme le décalage Doppler et/ou l'information angulaire des multi-trajets, qui permettent de diminuer les ambiguïtés et d'améliorer les performances de détection et localisation.
 - L'évaluation du nombre de trajets pris en compte pour la localisation et le pistage de la cible, qui permet d'améliorer les performances de localisation. Jusqu'à présent, le nombre de trajets pour la localisation est choisi par l'algorithme de sélection du nombre de trajets. Or, cet algorithme est développé pour maximiser la probabilité de détection et peut être sous-optimal pour la localisation. Par exemple, nous avons vu au chapitre 2 que le fait d'appliquer la sélection du nombre de trajets dégrade la performance de localisation sur les forts SNRs.
 - Un travail plus poussé pour le choix des bornes d'estimation qui permettent de prendre en compte les lobes secondaires liés aux ambiguïtés. Le calcul de ces bornes devrait pouvoir permettre de prédire, à partir d'une géométrie donnée, les capacités de localisation du système radar around-the-corner en fonction de la position de la cible. En particulier cela pourrait permettre d'évaluer l'utilisation du radar en fonction de la géométrie considérée.
 - L'évaluation de l'impact de la géométrie de la scène et de la bande du signal émis sur la robustesse des algorithmes. Il nous faudra chercher un bon compromis entre la résolution distance (liée à la bande du signal émis) permettant de séparer les trajets et la robustesse aux « détails » de la scène. Pour être plus précis, une bande plus large permet de mieux séparer les trajets, mais en même temps rend le système plus sensible aux détails de la scène. Ces détails ne sont pas toujours connus et peuvent causer des ambiguïtés pour les algorithmes de localisation quand nous utilisons un modèle simplifié de la géométrie de la scène où les détails ne sont pas modélisés.
 - L'extension aux problèmes multi-cibles. Nous nous sommes restreints au cas monocible dans le cadre de cette thèse, car cela permettait une meilleure compréhension des différents phénomènes en jeu, et que les traitements étaient également simplifiés, au vu de la complexité du problème. L'extension au problème multi-cibles nécessite plus d'efforts pour gérer les problèmes d'association cibles/trajets, d'ambiguïtés pour la détection des cibles (car nombre de cibles inconnu), etc.
 - La prise en compte d'un modèle 3D pour certaines configurations ou besoins spécifiques.

Annexes

Annexe A

Dérivation de P_{FA} et P_d pour les algorithmes FMU et SLC

P_{FA} pour l'algorithme FMU

Sous l'hypothèse H_0 et en absence de la cible, $T'_{FMU}(x, y) = T_{FMU}(x, y)/(\sigma^2/2)$ suit une loi du χ^2 centrée à $2M(x, y)$ degrés de liberté [Scharf 94]. La probabilité de fausse alarme peut être calculée à partir de la fonction de distribution cumulative de la loi de χ^2 centrée :

$$P_{FA} = 1 - \frac{\gamma\left(M(x, y), \frac{\lambda'_{FMU}}{2}\right)}{\Gamma(M(x, y))},$$

où $\Gamma(N)$ et $\gamma(N, x)$ sont les fonctions gamma et les fonctions gamma incomplètes inférieures respectivement. Donc le seuil de la distribution $T_{FMU}(x, y)$ pour avoir une probabilité de fausse alarme P_{FA} est fourni par :

$$\lambda_{FMU} = \frac{\sigma^2}{2} \lambda'_{FMU} = \sigma^2 \gamma^{-1}(M(x, y), \Gamma(M(x, y))(1 - P_{FA})).$$

P_d pour l'algorithme FMU

Sous l'hypothèse H_1 et en présence de la cible, $T'_{MPF}(x, y)$ suit une loi de χ^2 non-centrée à $2M(x, y)$ degrés de liberté et de paramètre de non centralité $p_c = \|\mathbf{R}(x, y)\boldsymbol{\alpha}\|^2 / \sigma^2$ [Scharf 94]. La probabilité de détection peut être

calculée par :

$$\begin{aligned} P_{d(FMU)} &= P(T_{FMU}(x, y) > \lambda_{MPF}) \\ &= P(T'_{FMU}(x, y) > \lambda'_{MPF}) \\ &= \int_{\lambda'_{MPF}}^{\infty} f_{\chi^2}(y) dy, \end{aligned}$$

où f_{χ^2} est la densité de probabilité de la distribution χ^2 :

$$\begin{aligned} f_{\chi^2}(y) &= \frac{1}{2} \exp(-(y + p_c)/2) \left(\frac{y}{p_c}\right)^{(M(x,y)-1)/2} \\ &\times I_{M(x,y)-1}(\sqrt{p_c y}). \end{aligned}$$

Notons $x = \sqrt{y}$, nous avons

$$\begin{aligned} P_{d(FMU)} &= \int_{\sqrt{\lambda'_{MPF}}}^{\infty} \exp(-(x^2 + p_c)/2) \\ &\times x \left(\frac{x^2}{p_c}\right)^{(M(x,y)-1)/2} I_{M(x,y)-1}(\sqrt{p_c x^2}) dx \\ &= Q_{M(x,y)}\left(\frac{\|\mathbf{R}(x, y)\boldsymbol{\alpha}\|}{\sigma}, \sqrt{\lambda'_{FMU}}\right), \end{aligned}$$

en utilisant la définition de la fonction Q de Marcum fournie par l'équation (2.19)[Shnidman 89].

La dérivation de P_{FA} et P_d pour l'algorithme SLC est similaire car $T'_{SLC}(x, y) = T_{SLC}(x, y)/\sigma^2$, qui est une somme de carrés de variables gaussiennes, devrait également suivre une loi du χ^2 centrée sous l'hypothèse H_0 et non-centrée sous l'hypothèse H_1 avec le paramètre de non centralité $\sum_{i \in \Omega(x,y)} |[\mathbf{R}(x, y)\boldsymbol{\alpha}]_i|^2$.

Annexe B

Démonstration de la proposition 1

Nous allons considérer les deux probabilités de détection $P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ et $P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1})$ lorsque n et $n+1$ trajets sont pris en compte respectivement. Nous supposons que les trajets sont relativement séparés, alors $\mathbf{r}(\tau_i)$ et $\mathbf{r}(\tau_j)$ sont non corrélés pour toutes les paires (i, j) et sans perte de généralité que $|\alpha_1| \geq |\alpha_2| \geq \dots \geq |\alpha_{n+1}|$. Ainsi, les probabilités de détection du détecteur FMU avec n et $n+1$ trajets sont respectivement fournies par :

$$\begin{aligned} P_d^{(n)}(\boldsymbol{\alpha}_{1:n}) &= Q_n \left(\sqrt{2 \sum_{k=1}^n |\alpha_k|^2}, \sqrt{2t_n} \right) \\ &= Q_n \left(\sqrt{2\beta^2}, \sqrt{2t_n} \right), \end{aligned}$$

et

$$\begin{aligned} P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) &= Q_{n+1} \left(\sqrt{2 \sum_{k=1}^{n+1} |\alpha_k|^2}, \sqrt{2t_{n+1}} \right) \\ &= Q_{n+1} \left(\sqrt{2(\beta^2 + |\alpha_{n+1}|^2)}, \sqrt{2t_{n+1}} \right), \end{aligned}$$

où $\beta^2 = \sum_{k=1}^n |\alpha_k|^2$, $t_n = \gamma^{-1}(n, \Gamma(n)(1 - P_{fa}))$, $t_{n+1} = \gamma^{-1}(n+1, \Gamma(n+1)(1 - P_{fa}))$ et la fonction Q de Marcum est définie par :

$$Q_M(a, b) = \int_b^\infty x \left(\frac{x}{a}\right)^{M-1} \exp\left(-\frac{x^2 + a^2}{2}\right) I_{M-1}(ax) dx$$

Notons

$$\Delta P_{n+1}(\beta, |\alpha_{n+1}|) = P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) - P_d^{(n)}(\boldsymbol{\alpha}_{1:n}),$$

il vient que

$$\begin{aligned} \Delta P_{n+1}(\beta, |\alpha_{n+1}|) &= Q_{n+1} \left(\sqrt{2(\beta^2 + |\alpha_{n+1}|^2)}, \sqrt{2t_{n+1}} \right) \\ &\quad - Q_n \left(\sqrt{2\beta^2}, \sqrt{2t_n} \right). \end{aligned}$$

La simulation numérique montre qu'il existe $|\alpha'| \in (0, |\alpha_n|)$ pour que $\Delta P_{n+1}(\beta, |\alpha_{n+1}|) > 0$ quand $|\alpha_{n+1}| > |\alpha'|$ et $\Delta P_{n+1}(\beta, |\alpha_{n+1}|) < 0$ quand $|\alpha_{n+1}| < |\alpha'|$. De manière asymptotique, nous montrons que :

- (*) : $\Delta P_{n+1}(\beta, |\alpha_{n+1}|)$ augmente avec $|\alpha_{n+1}|$,
- (**) : $\Delta P_{n+1}(\beta, 0) < 0$ et $\Delta P_{n+1}(\beta, |\alpha_{n+1}| = |\alpha_n|) > 0$, sous l'hypothèse que β est suffisamment grand.

Pour prouver (*), remarquons que

$$\frac{\partial \Delta P_{n+1}(\beta, |\alpha_{n+1}|)}{\partial |\alpha_{n+1}|} = \frac{\partial Q_{n+1} \left(\sqrt{2(\beta^2 + |\alpha_{n+1}|^2)}, \sqrt{2t_{n+1}} \right)}{\partial |\alpha_{n+1}|}.$$

et que

$$\frac{\partial Q_{n+1} \left(\sqrt{2(\beta^2 + |\alpha_{n+1}|^2)}, \sqrt{2t_{n+1}} \right)}{\partial |\alpha_{n+1}|} > 0,$$

car $Q_M(a, b)$ croît avec a [Gil 14]. Ainsi

$$\frac{\partial \Delta P_{n+1}(\beta, |\alpha_{n+1}|)}{\partial |\alpha_{n+1}|} > 0.$$

Donc, $\Delta P_{n+1}(\beta, |\alpha_{n+1}|)$ augmente quand $|\alpha_{n+1}|$ augmente dans l'intervalle $[0; |\alpha_n|]$. (*) est prouvé!

Pour prouver (**), nous pouvons écrire $\Delta P_{n+1}(\beta, 0) = Q_{n+1}(\beta\sqrt{2}, \sqrt{2t_{n+1}}) - Q_n(\beta\sqrt{2}, \sqrt{2t_n})$. A partir de [Nuttall 75], [Esposito 68] et [Yu 12], nous avons :

$$\begin{aligned} \frac{\partial Q_M(a, b)}{\partial a} &= a [Q_{M+1}(a, b) - Q_M(a, b)] \\ &= a \left(\frac{b}{a} \right)^M \exp\left(-\frac{a^2 + b^2}{2}\right) I_M(ab). \end{aligned}$$

Puis, notons

$$\begin{aligned} f_{n+1}(\beta) &= \frac{\partial \Delta P_{n+1}(\beta, 0)}{\partial \beta} \\ &= \beta^{-n+1} \sqrt{2} t_{n+1}^{(n+1)/2} \exp\left[-(\beta^2 + t_{n+1})\right] I_n(2\beta\sqrt{t_n}) \\ &\quad \times \left[\frac{1}{\beta} \frac{I_{n+1}(2\beta\sqrt{t_{n+1}})}{I_n(2\beta\sqrt{t_n})} - \frac{t_n^{n/2}}{t_{n+1}^{(n+1)/2}} \exp(t_{n+1} - t_n) \right], \end{aligned}$$

Nous avons $\beta^{-n+1} \sqrt{2} t_{n+1}^{(n+1)/2} \exp[-(\beta^2 + t_{n+1})] I_n(2\beta\sqrt{t_n}) > 0$ et à partir de [AlHasan 13] :

$$\begin{aligned} \lim_{\beta \rightarrow +\infty} \frac{1}{\beta} \frac{I_{n+1}(2\beta\sqrt{t_{n+1}})}{I_n(2\beta\sqrt{t_n})} &= \lim_{\beta \rightarrow +\infty} \frac{1}{\beta} \sqrt{\frac{t_n}{t_{n+1}}} \frac{\exp(2\beta\sqrt{t_{n+1}})}{\exp(2\beta\sqrt{t_n})} \\ &= +\infty \end{aligned}$$

(car $t_{n+1} > t_n$). En outre, $\frac{t_n^{(n)/2}}{t_{n+1}^{(n+1)/2}} \exp(t_{n+1} - t_n)$ est une constante positive. Donc,

$$\lim_{\beta \rightarrow +\infty} f_{n+1}(\beta) = +\infty.$$

Comme la fonction $f_{n+1}(\beta)$ est continue pour $\beta \in (0, +\infty)$; il existe donc β_1 de sorte que pour tout $\beta > \beta_1$, $f_{n+1}(\beta)$ est positif. C'est-à-dire, $\Delta P_{n+1}(\beta, 0)$ augmente dans l'intervalle $[\beta_1, +\infty]$. En outre, $\Delta P_{n+1}(\beta, 0)$ est continue et $\lim_{\beta \rightarrow +\infty} \Delta P_{n+1}(\beta, 0) = 1 - 1 = 0$. Donc $\Delta P_{n+1}(\beta, 0) < 0$ pour tout $\beta > \beta_1$.

De la même manière, nous pouvons montrer qu'il existe β_2 tel que $\Delta P_{n+1}(\beta, |\alpha_{n+1}| = |\alpha_n|) > 0$ pour tout $\beta > \beta_2$.

Alors, prenons $\beta_0 = \max(\beta_1, \beta_2)$, il vient que pour tout $\beta > \beta_0$: $\Delta P_{n+1}(\beta, 0) < 0$ et $\Delta P_{n+1}(\beta, |\alpha_{n+1}| = |\alpha_n|) > 0$. (**) est prouvé!

Table des figures

0.0.1	La présence des zones d'ombre et des multi-trajets en milieu urbain.	2
1.1.1	Principe du radar classique.	8
1.1.2	Chaîne classique de traitement radar	11
1.1.3	Exemple de la fonction d'ambiguïté d'un signal à modulation linéaire de fréquence d largeur de bande de 100 MHz.	16
1.1.4	Forme d'onde LFM avec largeur de bande de 400 MHz.	17
1.1.5	Module de l'auto-corrélation circulaire des séquences SBLM et Zadoff-Chu de longueur 63 (N=6).	18
1.1.6	Principe général du filtre particulaire.	27
1.2.1	Spectre de différentes formes d'onde.	31
1.2.2	Robustesse Doppler de différentes formes d'onde : $R(\nu) = \max_{\tau} (\chi(\tau, \nu))$ pour $f_0 = 9,6$ GHz.	33
1.2.3	Un radar around-the-corner en milieu urbain.	35
2.1.1	Un radar urbain exploitant les réflexions pour détecter des cibles en NLOS.	40
2.2.1	Perte de diffraction obtenue par résolution de l'intégrale de Fresnel pour le problème de diffraction en lame de couteau (solution de Sommerfeld) [Sommerfeld 04].	41
2.3.1	Schéma de principe de la méthode des empreintes digitales. . .	45
2.3.2	Exemple de la construction d'une empreinte digitale.	46
2.3.3	Scénario d'une intersection urbaine typiquement considérée. . .	49
2.4.1	$P_d^{(n+1)}(\boldsymbol{\alpha}_{1:n+1}) - P_d^{(n)}(\boldsymbol{\alpha}_{1:n})$ pour différentes valeurs de n et différents SNR de trajets.	54
2.4.2	P_d en fonction du nombre de multi-trajets pour différents SNRs du premier trajet. Les croix rouges représentent le maximum de P_d pour chaque courbe.	56
2.5.1	Scénario d'intersection urbaine simulé pour les mesures de performances.	58

2.5.2	Carte du nombre optimal de multi-trajets trouvée par l'algorithme de sélection du nombre de trajets comparée avec la carte théorique.	59
2.5.3	Probabilité de détection en fonction du SNR. Cible localisée à la position de référence (39, 875; 10, 125). $M_{opt} = 2$ pour les algorithmes FMU et SLC. $P_{fa} = 10^{-3}$. Pertes $\sum_i \nu_i ^2 = 7.12$ dB.	60
2.5.4	Probabilité de détection en fonction du SNR. Cible localisée à la position (35, 125; 12, 125). $M_{opt} = 3$ pour les algorithmes FMU et SLC. $P_{fa} = 10^{-3}$. Pertes $\sum_i \nu_i ^2 = 15.91$ dB.	61
2.5.5	Résultat de la localisation pour une cible à (32; 14, 25) (gauche) et (37; 14, 25) (droite). La croix noire représente la vraie position de la cible. SNR=15 dB.	63
2.5.6	Erreur de localisation le long de la trajectoire cible. SNR=15dB.	64
2.6.1	Exemple des empreintes digitales de deux positions ambiguës.	68
2.6.2	Différentes positions de la cible considérés.	69
2.6.3	P_l et REQM en fonction du SNR pour différentes positions de la cible.	70
2.6.4	Courbes de P_l et REQM en moyennant sur toutes les cases. Le nombre de trajets pour chaque case est choisi par l'algorithme de sélection du nombre de trajets.	71
2.6.5	Courbes de P_l et REQM en moyennant sur toutes les cases. Le nombre de trajets par chaque case est choisi par une simulation de tracé de rayons (sans application de l'algorithme de sélection du modèle).	72
3.6.1	Structure de l'inverse de la matrice de Fisher $\mathbf{J}^{-1}(\mathbf{x}_{0:k})$	86
3.7.1	Scénario d'une intersection urbaine typique considéré.	90
3.7.2	Schéma des deux trajectoires examinées.	91
3.7.3	Comparaison de la REQM du filtre particulaire GLRT avec différentes valeurs de σ_α , celle du filtre particulaire classique et celle de la localisation sans pistage (FMU) pour la trajectoire 1. SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	92
3.7.4	Résultat de la localisation FMU et du filtre particulaire GLRT quand la cible est à la position (32, 16.25) (première itération). Le cercle noir indique la vraie position de la cible.	93
3.7.5	Résultat de la localisation FMU et du filtre particulaire GLRT quand la cible est à la position (33, 5; 16, 25) (16-ème itération). Le cercle noir indique la vraie position de la cible.	93

3.7.6	Comparaison de la REQM du filtre particulaire avec différentes valeurs de σ_α , celle du filtre particulaire classique et celle de la localisation sans pistage (FMU) pour la trajectoire 1. SNR=15 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	94
3.7.7	Comparaison de la REQM du filtre particulaire avec différentes valeurs de σ_α , celle du filtre particulaire classique et celle de la localisation sans pistage (FMU) pour la trajectoire 2. SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	95
3.7.8	Performances du filtre particulaire Swerling I (approche 1) pour différentes configurations examinées. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	96
3.7.9	Filtre particulaire Swerling I/ approche 2 avec différentes initialisations de $(\sigma_\rho)_0^i$: trajectoire 1 et SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	97
3.7.10	Filtre particulaire Swerling I/ approche 2 avec différentes initialisations de $(\sigma_\rho)_0^i$: trajectoire 1 et SNR=15 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	98
3.7.11	Filtre particulaire Swerling I/ approche 2 avec différentes initialisations de $(\sigma_\rho)_0^i$: trajectoire 2 et SNR=10 dB. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	99
3.7.12	Comparaison des performances de différents filtres pour différentes configurations examinées. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$	101
3.7.13	Performances de différents filtres moyennées sur des trajectoires tirées aléatoirement. $N_p = 1600$. $\beta = 1/3$. $N_{MC} = 1000$. .	102
3.7.14	Performances des filtres pour la trajectoire 1 et 2 de la configuration représentée par la figure 3.7.2 ($N_p = 1600$, $\beta = 1/3$, $N_{MC} = 1000$) par rapport à la borne de Cramér-Rao a posteriori conditionnelle. SNR=10 dB.	104
4.1.1	Radar utilisé pour les expérimentations (IMST 24 GHz 2-Channel FMCW Radar). Source : www.imst.com	108
4.1.2	Scénario des mesures réelles : le radar a été placé à l'extrémité du tunnel (cercle bleu). La cible (piéton) se déplaçait dans la section droite de la jonction (rectangle rose).	109
4.1.3	Configuration des dispositifs de mesure.	109
4.1.4	Photo d'un piéton considéré comme cible en déplacement.	110
4.1.5	Schéma représentatif du scénario : les segments verts correspondent à des échos fixes, les segments bleus et rouges représentent respectivement des trajectoires radar-cible avec des réflexions à un et deux rebonds.	111

4.2.1	Réponse Doppler à un instant donné.	111
4.2.2	Profils distance avant filtrage zéro-Doppler pour le scénario décrit en paragraphe 4.1.2.	112
4.2.3	Profils distance après filtrage zéro-Doppler pour le scénario décrit en paragraphe 4.1.2.	112
4.2.4	Profils distance simulés. Écho rouge, orange, vert, bleu ciel et bleu marine : trajets avec zéro, une, deux, trois et quatre réflexions sur les murs respectivement.	113
4.3.1	Exemples de localisation par l'algorithme FMU sur les données expérimentales du scénario de la figure 4.1.5. La vraie position de la cible est représentée par le cercle noir.	115
4.3.2	Exemples de localisation par l'algorithme SLC sur les données expérimentales du scénario de la figure 4.1.5. La vraie position de la cible est représentée par le cercle noir.	116
4.3.3	Localisation de la cible située en position (15, 5; 16, 2).	117
4.3.4	Exemples de l'erreur de localisation par l'algorithme FMU à cause des ambiguïtés. La vraie position de la cible est représentée par le cercle noir. La position estimée est indiquée par le cercle vert.	118
4.3.5	Erreur de localisation le long de la trajectoire cible.	119
4.3.6	Erreur de localisation le long de la trajectoire cible des algorithmes FMU et SLC sur les signaux après traitement d'intégration Doppler.	120
4.4.1	Erreur de localisation le long de la trajectoire cible du filtre particulaire GLRT et de l'algorithme FMU.	121
4.4.2	Sortie du test de localisation FMU et les particules du filtre particulaire GLRT (itérations 1-4).	122
4.4.3	Sortie du test de localisation FMU et les poids des particules du filtre particulaire GLRT (itérations 5-8).	123
4.4.4	Erreur de localisation le long de la trajectoire en sens inverse de la cible.	124
4.4.5	Sortie du test de localisation FMU et les particules du filtre particulaire GLRT pour la trajectoire en sens inverse de la cible (itérations 1-7).	125
4.4.6	Sortie du test de localisation FMU et les particules du filtre particulaire GLRT pour la trajectoire en sens inverse de la cible (itérations 9-15).	126
4.4.7	Résultats du filtre particulaire Swerling I avec approche I pour différentes valeurs du paramètre σ_ρ	127

4.4.8	Erreur de localisation le long de la trajectoire de la cible pour les différents filtres particuliers.	128
4.4.9	Erreur de localisation le long de la trajectoire en sens inverse de la cible pour différents filtres particuliers.	128

Liste des tableaux

1.1	Comparaison des lobes secondaires de différentes formes d'onde.	30
2.1	Comparaison de la mémoire nécessaire et du temps de calcul pour l'algorithme SLC et les trois implémentations possibles de l'algorithme FMU. $N = 300$, $M(x, y) = 3$, zone d'intérêt avec 40x40 cases. Environnement Matlab, PC 2.8 GHz.	52
4.1	Paramètres du radar utilisé.	108
4.2	Tableau récapitulatif des performances de détection et localisation des algorithmes FMU et SLC.	120

Liste des Algorithmes

1	Sélection du nombre de trajets pris en comptes	57
2	Filtre particulaire GLRT à l'itération k.	81
3	Filtre particulaire Swerling I/ approche 1 à l'itération k.	83
4	Filtre particulaire Swerling I/ approche 2 à l'itération k.	84

Bibliographie

- [Akaike 74] H. Akaike. *A new look at the statistical model identification*. IEEE transactions on automatic control, vol. 19, no. 6, pages 716–723, 1974.
- [AlHasan 13] A. AlHasan, S. Mohammadet al. *A simple and efficient approximation to the modified Bessel functions and its applications to Rician fading*. IEEE GCC Conference and Exhibition (GCC), 2013.
- [Andrieu 04] C. Andrieu, A. Doucet, S. Singh & V. Tadic. *Particle methods for change detection, system identification, and control*. Proceedings of the IEEE, vol. 92, no. 3, pages 423–438, 2004.
- [Arulampalam 02] M.S. Arulampalam, S. Maskell, N. Gordon & T. Clapp. *A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking*. IEEE Transactions on signal processing, vol. 50, no. 2, pages 174–188, 2002.
- [Athans 68] M. Athans, R. Wishner & A. Bertolini. *Suboptimal state estimation for continuous-time nonlinear systems from discrete noisy measurements*. IEEE Transactions on Automatic Control, vol. 13, no. 5, pages 504–514, 1968.
- [Bahl 00] P. Bahl & V. Padmanabhan. *RADAR : An in-building RF-based user location and tracking system*. In INFO-COM 2000. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Proceedings. IEEE, volume 2, pages 775–784. Ieee, 2000.
- [Bar-Shalom 04] Y. Bar-Shalom, X.R. Li & T. Kirubarajan. *Estimation with applications to tracking and navigation : theory algorithms and software*. John Wiley & Sons, 2004.
- [Barbosa 08] P. Barbosa, E. Chong, S. Suvorova & B. Moran. *Multitarget multisensor tracking in an urban environment : A closed-loop approach*. In Proceedings of the Conference on Signal

- and Data Processing of Small Targets 2008, part of the SPIE Symposium on Defense and Security, volume 6969, pages 69690W1–69690W12, 2008.
- [Bosse 15] J. Bosse, O. Rabaste & D. Poullin. *Matching pursuit via Continuous resolution cell rejection in presence of unresolved radar targets*. In Proceedings of the European Signal Processing Conference (EUSIPCO), pages 1816–1820, 2015.
- [Castro 01] P. Castro, P. Chiu, T. Kremenek & R. Muntz. *A probabilistic room location service for wireless networked environments*. In International conference on ubiquitous computing, pages 18–34. Springer, 2001.
- [Chakraborty 10] B. Chakraborty, Y. Li, J. J. Zhang & T. Trueblood. *Multipath exploitation with adaptive waveform design for tracking in urban terrain*. In Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, pages 3894–3897, 2010.
- [Chu 72] D. Chu. *Polyphase codes with good periodic correlation properties (corresp.)*. IEEE Transactions on information theory, vol. 18, no. 4, pages 531–532, 1972.
- [Colone 09] F. Colone, D. W. O. Hagan, P. Lombardo & C. J. Baker. *A Multistage Processing Algorithm for Disturbance Removal and Target Detection in Passive Bistatic Radar*. IEEE Transactions on Aerospace and Electronic Systems, vol. 45, no. 2, pages 698–722, apr 2009.
- [Davey 12] S.J. Davey, M.G. Rutten & B. Cheung. *Using phase to improve track-before-detect*. IEEE transactions on Aerospace and Electronic Systems, vol. 48, no. 1, pages 832–849, 2012.
- [Doucet 01] A. Doucet, N. de Freitas & N. Gordon. *Sequential monte carlo methods in practice*. Information Science and Statistics. Springer, 2001.
- [Dziak 17] J. Dziak, D. Coffman, S. Lanza & R. Li. *Sensitivity and specificity of information criteria*. PeerJ PrePrints, 2017.
- [Esposito 68] R. Esposito. *Comment on "Partial differentials of Marcum's Q function"*. In Proceedings of the IEEE, volume 56, page 2195, December 1968.
- [Foschini 98] G. Foschini & M. Gans. *On limits of wireless communications in a fading environment when using multiple anten-*

-
- nas.* Wireless personal communications, vol. 6, no. 3, pages 311–335, 1998.
- [Gil 14] A. Gil, J. Segura & N. M. Temme. *The asymptotic and numerical inversion of the Marcum Q–function*. Studies in Applied Mathematics, 2014.
- [Gordon 93] N. Gordon, D. Salmond & A. Smith. *Novel approach to nonlinear/non-Gaussian Bayesian state estimation*. In IEE Proceedings F (Radar and Signal Processing), volume 140, pages 107–113. IET, 1993.
- [Gustafsson 16] M. Gustafsson, A. Andersson, T. Johansson, S. Nilsson & A. Sume. *Extraction of Human Micro-Doppler Signature in an Urban Environment Using a "Sensing-Behind-the-Corner" Radar*. IEEE Transactions on GeoScience and Remote Sensing, vol. 13, pages 187–191, 2016.
- [Ho 64] YC Ho & RCKA Lee. *A Bayesian approach to problems in stochastic estimation and control*. IEEE Transactions on Automatic Control, vol. 9, no. 4, pages 333–339, 1964.
- [Ito 00] K. Ito. *Gaussian filter for nonlinear filtering problems*. In Decision and Control, 2000. Proceedings of the 39th IEEE Conference on, volume 2, pages 1218–1223. IEEE, 2000.
- [Johansson 11] T. Johansson, J. Rahm, J. Gustavsson, S. Nilsson, A. Sume & A. Örbom. *Through-the-wall detection of human activity*. In Radar Sensor Technology XV, volume 8021, page 80211O. International Society for Optics and Photonics, 2011.
- [Johansson 14] T. Johansson, A. Örbom, A. Sume, J. Rahm, S. Nilsson, M. Herberthson, M. Gustafsson & A. Andersson. *Radar measurements of moving objects around corners in a realistic scene*. In Proceedings of SPIE, Radar Sensor Technology, volume 9077, 2014.
- [Johansson 17] T. Johansson, A. Andersson, M. Gustafsson & S. Nilsson. *Positioning of Moving Non-Line-of-Sight Targets Behind a Corner*. In Proceedings of the 13th European Radar Conference, 2017.
- [John 02] P. John & S. Masoud. Communication systems engineering, chapitre 10, pages 689–694. Prentice Hall, 2002.
- [Kaemarungsi 04] K. Kaemarungsi & P. Krishnamurthy. *Modeling of indoor positioning systems based on location fingerprinting*. In INFOCOM 2004. Twenty-third Annual Joint Conference of the

- IEEE Computer and Communications Societies, volume 2, pages 1012–1022. IEEE, 2004.
- [Kalman 60] R.E. Kalman. *A new approach to linear filtering and prediction problems*. Journal of basic Engineering, vol. 82, no. 1, pages 35–45, 1960.
- [Kay 13] S. Kay. Fundamentals of statistical signal processing : Practical algorithm development, volume 3. Pearson Education, 2013.
- [Kerr 89] T. Kerr. *Status of CR-like lower bounds for nonlinear filtering*. IEEE Transactions on Aerospace and Electronic Systems, vol. 25, no. 5, pages 590–601, 1989.
- [Kitagawa 96] G. Kitagawa. *Monte Carlo filter and smoother for non-Gaussian nonlinear state space models*. Journal of computational and graphical statistics, vol. 5, no. 1, pages 1–25, 1996.
- [Kitagawa 98] G. Kitagawa. *A self-organizing state-space model*. Journal of the American Statistical Association, pages 1203–1215, 1998.
- [Korkmaz 08] S. Korkmaz & A. van der Veen. *Time delay estimation in dense multipath with matched subspace filters*. In Positioning, Navigation and Communication, 2008. WPNC 2008. 5th Workshop on, pages 79–87. IEEE, 2008.
- [Krolik 06] J. Krolik, J. Farrell & A. Steinhardt. *Exploiting multipath propagation for GMTI in urban environments*. In Radar, 2006 IEEE Conference on, pages 4–pp. IEEE, 2006.
- [Lagrange 12] X. Lagrange. *Principe de la transmission OFDM-utilisation dans les systemes cellulaires*. 2012.
- [Le Chevalier 02] F. Le Chevalier. Principles of radar and sonar signal processing. Artech House, 2002.
- [Lepoutre 12] A. Lepoutre, O. Rabaste & F. Le Gland. *Optimized instrumental density for particle filter in track-before-detect*. 2012.
- [Lepoutre 16] A. Lepoutre. *Detection and Tracking in Track-Before-Detect via Particle Filter*. PhD thesis, Université de Rennes, 2016.
- [Levanon 04] N. Levanon & E. Mozeson. Radar signals. John Wiley & Sons, 2004.

- [Linnehan 09] R. Linnehan & J. Schindler. *Multistatic scattering from moving targets in multipath environments*. In Proceedings of the IEEE International Radar Conference, pages 1–6, 2009.
- [Liu 98] J. Liu & R. Chen. *Sequential Monte Carlo methods for dynamic systems*. Journal of the American statistical association, vol. 93, no. 443, pages 1032–1044, 1998.
- [MacCormick 00] J. MacCormick & A. Blake. *A probabilistic exclusion principle for tracking multiple objects*. International Journal of Computer Vision, vol. 39, no. 1, pages 57–71, 2000.
- [Merrill 62] I.S. Merrill. Introduction to radar systems. McGraw-Hill, 1962.
- [Musso 01] C. Musso, N. Oudjane & F. Le Gland. *Improving regularized particle filters*. In Sequential Monte Carlo methods in practice, pages 247–271. Springer, 2001.
- [Nuttall 75] A.H. Nuttall. *Some Integrals Involving the QM Function*. IEEE Transactions on Information Theory, vol. 21, pages 95–96, 1975.
- [O’connor 15] A. O’connor, P. Setlur & N. Devroye. *Single-sensor RF emitter localization based on multipath exploitation*. IEEE Transactions on Aerospace and Electronic Systems, vol. 51, no. 3, pages 1635–1651, 2015.
- [Parker 03] M. Parker, K. Paterson & C. Tellambura. *Golay complementary sequences*. Encyclopedia of Telecommunications, 2003.
- [Poullin 05] D. Poullin. *Clutter rejection in a passive radar receiver of OFDM signals*, August 2 2005. US Patent 6,924,763.
- [Rabaste 12] O. Rabaste, C. Riché & A. Lepoutre. *Long-time coherent integration for low SNR target via particle filter in track-before-detect*. In Information Fusion (FUSION), 2012 15th International Conference on, pages 127–134. IEEE, 2012.
- [Rabaste 15] O. Rabaste, E. Colin-Koeniguer, D. Poullin, A. Cheraly, J.-F. Pétex & H.-K. Phan. *Around-the-Corner Radar : Detection of a Human Being in Non Line of Sight*. IET Radar, Sonar and Navigation, vol. 9, no. 6, pages 660–668, 2015.
- [Richards 05] M. A. Richards. Fundamentals of radar signal processing. Tata McGraw-Hill Education, 2005.

- [Rutten 05] M.G. Rutten, B. Ristic & N.J. Gordon. *A comparison of particle filters for recursive track-before-detect*. In Information Fusion, 2005 8th International Conference on, volume 1, pages 7–pp. IEEE, 2005.
- [Scharf 94] L. Scharf & B. Friedlander. *Matched Subspace Detectors*. IEEE Transactions on Signal Processing, vol. 42, no. 8, pages 2146–2157, 1994.
- [Schwarz 78] G. Schwarz *et al.* *Estimating the dimension of a model*. The annals of statistics, vol. 6, no. 2, pages 461–464, 1978.
- [Setlur 12] P. Setlur, G. Smith, F. Ahmad & M. Amin. *Target localization with a single sensor via multipath exploitation*. IEEE Transactions on Aerospace and Electronic Systems, vol. 48, no. 3, pages 1996–2014, 2012.
- [Setlur 13] P. Setlur & N. Devroye. *Multipath exploited Bayesian and Cramer-Rao bounds for single-sensor target localization*. EURASIP Journal on Advances in Signal Processing, vol. 2013, no. 1, page 53, 2013.
- [Setlur 14] P. Setlur, T. Negishi, N. Devroye & D. Erricolo. *Multipath exploitation in non-LOS urban synthetic aperture radar*. IEEE Journal of Selected Topics in Signal Processing, vol. 8, no. 1, pages 137–152, 2014.
- [Shnidman 89] D.A. Shnidman. *The calculation of the probability of detection and the generalized Marcum Q-function*. IEEE Transactions on Information Theory, 1989.
- [Smailagic 00] A. Smailagic, J. Small & D.P. Siewiorek. *Determining user location for context aware computing through the use of a wireless LAN infrastructure*. Institute for Complex Engineered Systems Carnegie Mellon University, Pittsburgh, PA, vol. 15213, 2000.
- [Sommerfeld 04] A. Sommerfeld. *Mathematical theory of diffraction*. In Mathematical Theory of Diffraction, pages 9–68. Springer, 2004.
- [Stoica 04] P. Stoica & Y. Selen. *Model-order selection : a review of information criterion rules*. IEEE Signal Processing Magazine, vol. 21, no. 4, pages 36–47, 2004.
- [Stoica 12] P. Stoica & P. Babu. *On the proper forms of BIC for model order selection*. IEEE Transactions on Signal Processing, vol. 60, no. 9, pages 4956–4961, 2012.

- [Storvik 02] G. Storvik. *Particle filters for state-space models with the presence of unknown static parameters*. IEEE Transactions on signal Processing, vol. 50, no. 2, pages 281–289, 2002.
- [Sume 11] A. Sume, M. Gustafsson, M. Herberthson, A. Jänis, S. Nilsson, J. Rahm & A. Örbom. *Radar Detection of Moving Targets Behing Corners*. IEEE Transactions on GeoScience and Remote Sensing, vol. 49, pages 2259–2267, 2011.
- [Tahmoush 12] D. Tahmoush, J. Silvius & B. Bender. *Radar surveillance in urban environments*. In Proceedings of the IEEE International Radar Conference, pages 220–225, 2012.
- [Takenga 07] C. Takenga & K. Kyamakya. *A low-cost fingerprint positioning system in cellular networks*. In Communications and Networking in China, 2007. CHINACOM'07. Second International Conference on, pages 915–920. IEEE, 2007.
- [Tanizaki 13] H. Tanizaki. *Nonlinear filters : estimation and applications*. Springer Science & Business Media, 2013.
- [Telatar 99] E. Telatar. *Capacity of Multi-antenna Gaussian Channels*. Transactions on Emerging Telecommunications Technologies, vol. 10, no. 6, pages 585–595, 1999.
- [Tichavsky 98] P. Tichavsky, C.H. Muravchik & A. Nehorai. *Posterior Cramér-Rao bounds for discrete-time nonlinear filtering*. IEEE Transactions on signal processing, vol. 46, no. 5, pages 1386–1396, 1998.
- [Van Trees 04] H. Van Trees. *Optimum array processing : Part iv of detection, estimation, and modulation theory*. John Wiley & Sons, 2004.
- [Wan 01] E.A. Wan & R. Van Der Merwe. *The unscented Kalman filter*. Kalman filtering and neural networks, vol. 5, no. 2007, pages 221–280, 2001.
- [Weiss 11] A. Weiss. *Direct geolocation of wideband emitters based on delay and Doppler*. IEEE Transactions on Signal Processing, vol. 59, no. 6, pages 2513–2521, 2011.
- [Yu 12] A.B. Yu. *On some properties of the Marcum Q function*. Integral Transforms and Special Functions, pages 177–182, 2012.
- [Zadoff 63] S. Zadoff. *Phase coded communication system*, July 30 1963. US Patent 3,099,796.

- [Zetik 06] R. Zetik, S. Crabbe, J. Krajnak, P. Peyerl, J. Sachs & R. Thomä. *Detection and localization of persons behind obstacles using M-sequence through-the-wall radar*. In Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense V, volume 6201, page 62010I. International Society for Optics and Photonics, 2006.
- [Zetik 15] R. Zetik, M. Eschrich, S. Jovanoska & R. Thoma. *Looking behind a corner using multipath-exploiting UWB radar*. IEEE Trans. on Aerospace and Electronic Systems, vol. 51, no. 3, pages 1916–1926, 2015.
- [Zheng 12] Y. Zheng, O. Ozdemir, R. Niu & P.K. Varshney. *New conditional posterior Cramér-Rao lower bounds for nonlinear sequential Bayesian estimation*. IEEE transactions on signal processing, vol. 60, no. 10, pages 5549–5556, 2012.
- [Zuo 11] L. Zuo, R. Niu & P.K. Varshney. *Conditional posterior Cramér-Rao lower bounds for nonlinear sequential Bayesian estimation*. IEEE Transactions on Signal Processing, vol. 59, no. 1, pages 1–14, 2011.

Radar "Around-the-Corner": détection et localisation de cibles masquées en milieu urbain

Les applications des techniques radar au milieu urbain constituent un domaine émergent. Une des difficultés principale est liée à la complexité du milieu de propagation induit par les bâtiments présents dans la scène. En effet, contrairement aux applications radar classiques où la cible est en ligne de vue du radar, la présence de ces bâtiments génère d'une part des zones d'ombre à l'intérieur desquelles une cible n'est pas en visibilité directe, et d'autre part de nombreux multi-trajets produits par les possibles réflexions et diffractions sur les surfaces environnantes. Ces multi-trajets sont souvent vus comme une gêne, limitant les capacités de détection en radar. Or ils peuvent aussi être exploités à l'avantage du radar afin de détecter et localiser des cibles situées dans les zones d'ombre (cible en NLOS).

L'objectif de ce travail de thèse est donc la mise en place de méthodes de traitement du signal permettant la détection et la localisation d'une cible en NLOS en milieu urbain et l'application de ces techniques pour détecter et localiser une cible en NLOS à partir de signaux réalistes voire réels.

Pour cela, nous avons proposé dans un premier temps deux solutions pour la détection et la localisation de la cible en exploitant les multi-trajets : l'algorithme FMU qui est basé sur une projection du signal reçu sur le sous-espace défini par les retards des multi-trajets et l'algorithme SLC qui est basé sur une intégration non cohérente de l'énergie des multi-trajets. Nous avons également affiné d'une part notre solution de détection en proposant une méthode de sélection du nombre de trajets fondée sur l'optimisation de la probabilité de détection, et d'autre part notre solution de localisation en proposant d'utiliser des critères de pénalisation permettant de limiter dans une certaine mesure le problème d'ambiguïté inhérent à la problématique « around-the-corner ».

Dans un deuxième temps, nous avons développé deux filtres particuliers pour pister une cible en milieu urbain en présence de multi-trajets. Ces algorithmes ont été appliqués aux données réelles issues d'une expérimentation et ont montré des résultats prometteurs : même avec une connaissance approximative de la géométrie de la scène, il a été possible de détecter, localiser et suivre une cible en exploitant uniquement l'information fournie par les retards des multi-trajets.

Mots-clés : DETECTION ; FILTRE PARTICULAIRE ; LOCALISATION ; MILIEU URBAIN ; NLOS ; RADAR ; PISTAGE ; MULTI-TRAJETS

Around the Corner Radar : Detection and localization of an NLOS target in urban environment

The applications of radar techniques to the urban environment constitute an emerging subject. One of the main difficulties is related to the complexity of the propagation environment induced by the buildings present in the scene. Indeed, unlike conventional radar applications where the target is in line of sight of the radar, the presence of these buildings generates on the one hand shadow areas within which a target is not in line of sight, and on the other hand, many multipaths produced by reflections and diffractions on the surrounding surfaces. Classically, these multipaths are often seen as an inconvenience, limiting radar detection capabilities. However these multipaths can also be exploited to the advantage of the radar to detect and locate targets located in the shadows areas (target in NLOS).

The objective of this thesis work is therefore to develop signal processing methods allowing the detection and localization of a target located in shadow areas in urban environment and to apply these techniques for detecting and locating a target in NLOS from realistic or even real signals.

For this, we first proposed two solutions for detection and localization of a target by exploiting multipath information: the FMU algorithm which is based on a projection of the received signal on the subspace defined by the delays of the multipaths and the SLC algorithm that is based on a non-coherent integration of multipath energy. We have also improved on one hand our detection solution by proposing a method for selecting the number of paths based on the optimization of the probability of detection, and on the other hand our localization solution by proposing to use some penalization enabling to mitigate the ambiguity problem inherent to the "around-the-corner" problem. In a second step, we developed two particle filters to track a target in urban environment in the presence of multipaths. These algorithms have been applied to real data and showed promising results: even with an approximate knowledge of the geometry of the scene, it has been possible to detect, locate and track a target by exploiting only the information on multipath delays.

Keywords : DETECTION ; LOCALIZATION ; MULTIPATH ; NLOS ; PARTICLE FILTER ; RADAR ; TRACKING ; URBAN ENVIRONNEMENT