

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Ecole Nationale Polytechnique

Département d'Electronique

Laboratoire Signal & Communication



Thèse de Doctorat en Sciences

Présenté par :

AMROUCHE Naima

Titre

Algorithmes de poursuite de cibles

Thèse soutenu le 30/01/2019 devant le jury composé de :

Président	M. LARBES Cherif	Professeur, ENP
Examineur	M. AIT CHEIKH Mohamed Salah	Professeur, ENP
Examineur	M. CHIBANI Youcef	Professeur, USTHB
Examineur	M. GUESSOUM Abderrezak	Professeur, U.BLIDA1
Examineur	M. DJENDI Mohamed	Professeur, U.BLIDA1
Encadrant	M. BERKANI Daoud	Professeur, ENP
Co-Encadrant	M. KHENCHAF Ali	Professeur, ENSTA Bretagne

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Ecole Nationale Polytechnique

Département d'Electronique

Laboratoire Signal & Communication



Thèse de Doctorat en Sciences

Présenté par :

AMROUCHE Naima

Titre

Algorithmes de poursuite de cibles

Thèse soutenu le 30/01/2019 devant le jury composé de :

Président	M. LARBES Cherif	Professeur, ENP
Examineur	M. AIT CHEIKH Mohamed Salah	Professeur, ENP
Examineur	M. CHIBANI Youcef	Professeur, USTHB
Examineur	M. GUESSOUM Abderrezak	Professeur, U.BLIDA1
Examineur	M. DJENDI Mohamed	Professeur, U.BLIDA1
Encadrant	M. BERKANI Daoud	Professeur, ENP
Co-Encadrant	M. KHENCHAF Ali	Professeur, ENSTA Bretagne

ملخص: يهدف العمل المنجز في هذه الرسالة إلى تطوير منهجية لاكتشاف ومطاردة هدف أو أهداف متعددة باستخدام منهج المسار قبل الكشف (TBD). يتميز هذا المنهج باستغلال الإشارات الأولية بشكل مباشر لوظائف الكشف و المطاردة، من خلال الاستغناء عن الخطوة السابقة و المتمثلة في خطوة العتبة المستخدمة في المنهج التقليدي. يمكن تطبيق منهج TBD وفقاً لعدة طرق. يركز عملنا على إطار بايز باستخدام نماذج ماركوف المخفية، ويتم حل مشكلة TBD باستخدام تقريب الجسيمات. نبدأ أولاً بخوارزمية TBD استناداً إلى مرشح الجسيمات (PF) في حالة هدف واحد. نقترح تطبيقات مختلفة باستعمال قياسات مختلفة مثل قياسات الصور وقياسات الرادار مع الأخذ في عين الاعتبار مختلف أنواع المسارات بالنسبة للأهداف المناورة وغير المناورة، وبالتالي ضمان الكشف والتقدير في وجود أنواع مختلفة من المناورات. ثانياً، نسلط الضوء على منهج TBD القائم على مرشح الجسيمات في حالة تواجد عدة أهداف نقترح استخدام خوارزمية المطاردة المتعددة الأوضاع والمتعددة الأهداف و المطاردة قبل الكشف (MM-MT-TBDF) باستعمال مرشح الجسيمات، مما يتيح ظهور الأهداف واختفائها بمرور الوقت باستعمال قياسات مختلفة و عدة مسارات (أهداف مناورة و غير مناورة).

الكلمات الدالة: مطاردة الأهداف، المسار قبل الكشف، مرشح الجسيمات، الكشف

Abstract : The aim of the work presented in this thesis is to develop a methodology for the detection and tracking of one or multiple radar targets using the Track-Before-Detect (TBD) approach. This approach presents the advantage of directly exploiting the raw signals for detection and tracking purposes, freeing it from the prior thresholding step conventionally used. The TBD approach can be implemented according to several approaches. Our work concerns the Bayesian framework using particular hidden Markov models, and the TBD problem is solved using particle approximation. We first start with the TBD algorithm based on particle filtering in the case of a single target (mono-target). We propose different applications on different observations such as image measurements and radar measurements taking into account different types of trajectories for manoeuvring and non-maneuvring targets, thus ensuring detection and estimation in the presence of different types of manoeuvres. Secondly, we address the TBD approach based on particulate filtering in the case of several targets (multi-target). We propose to use the multi-mode multi-target track-before-detect algorithm (MM-MT-TBDF) based on particle filtering allowing the appearance and disappearance of targets over time on different measurements and for different types of trajectories of maneuvering and non-maneuvering targets.

Keywords: target tracking, track-before-detect, particulate filtering, detection.

Résumé : Les travaux réalisés dans le cadre de cette thèse ont pour objet le développement d'une méthodologie pour la détection et le pistage d'une ou plusieurs cibles radars en utilisant l'approche Track-Before-Detect (TBD). Cette approche a pour avantage d'exploiter directement les signaux bruts pour des fonctions de détection et de pistage, en s'affranchissant de l'étape de seuillage préalable classiquement utilisé. L'approche TBD peut être implémentée selon plusieurs approches. Notre travail concerne le cadre bayésien utilisant les modèles de Markov cachés particuliers, et le problème TBD est résolu en utilisant l'approximation particulaire. Nous commençons dans un premier temps par la présentation de l'algorithme TBD basé sur le filtrage particulaire, et en particulier dans le cas particulier d'une seule cible isolée (mono-cible). Nous proposons différentes applications selon les signaux considérés. Ainsi, nous avons généré des mesures radars prenant en compte différents types de trajectoires de cibles manouvrantes et non manouvrantes, assurant ainsi la détection et l'estimation en présence de différents types de manœuvres. Ensuite, nous nous sommes intéressés à l'approche TBD basée sur le filtrage particulaire dans le cas de plusieurs cibles (multi-cible). Dans ce cadre, nous proposons d'utiliser l'algorithme multi-mode multi-target track-before-detect (MM-MT-TBDF) basé sur le filtrage particulaire. Ceci a pour avantage de voir l'apparition et la disparition de cibles au cours du temps sur différentes mesures et pour différents types de trajectoires de cibles manouvrantes et non manouvrantes.

Mots clés : Poursuite de cibles, track-before-detect, filtrage particulaire, détection.

REMERCIEMENT

Je souhaite remercier en premier lieu mon co-directeur de thèse, M. Ali Khenchaf, Professeur des Universités à l'ENSTA Bretagne et responsable de l'équipe PIM du Lab-STICC (et aussi responsable du groupe REMS) pour m'avoir accueilli au sein de son équipe. Je lui suis également reconnaissante pour le temps conséquent qu'il m'a accordé, ses qualités pédagogiques et scientifiques, sa franchise et sa sympathie. J'ai beaucoup appris à ses côtés et je lui adresse ma gratitude pour tout cela. J'adresse mes remerciements à mon encadrant de thèse, M. Daoud Berkani, Professeur de l'Ecole National Polytechnique d'Alger, qui m'a fait l'honneur d'être mon directeur de thèse.

Je voudrais remercier les membres de jury de cette thèse M. Cherif Larbes, Professeur de l'Ecole Nationale Polytechnique d'Alger, M. Mohamed Salah Ait Cheikh, Professeur de l'Ecole Nationale Polytechnique d'Alger, M. Youcef Chibani, Professeur à l'Université des Sciences et de la Technologie Houari Boumediene, M. Abderrezak Guessoum, Professeur à l'Université de Blida1 et M. Mohamed Djendi, Professeur à l'Université de Blida1, pour avoir accepté examiner mon travail.

Je tiens à remercier tout particulièrement M^{elle} Zaynab Guerraou pour les nombreuses relectures de mon article. Elle a toujours répondu présente, même dans les cas les plus désespérés. Merci.

Je tiens ensuite à remercier tout spécialement M. Abdelmalek Toumi enseignant chercheur à l'ENSTA Bretagne pour ses conseils.

Je tiens également à remercier tous les membres de Lab-STICC et spécialement les membres de l'équipe PIM et du groupe REMS de l'ENSTA Bretagne.

Je remercie mon cher papa pour, son soutien, son encouragement au quotidien indéfectible à l'égard de mes travaux comme de la vie en général. Cette thèse et moi te devons beaucoup. Merci.

Mes remerciements vont aussi à ma famille et mes amis qui, avec cette question récurrente, « quand est-ce que tu la soutiens cette thèse ? », bien qu'angoissante en période fréquente de doutes, m'ont permis de ne jamais dévier de mon objectif final.

En fin je tiens à remercier du fond du cœur les personnes qui ont contribué de près ou de loin à l'élaboration de ce modeste travail.

SOMMAIRE

RESUME

LISTE DES FIGURES

LISTE DES TABLES

ABREVIATIONS USUELLES

INTRODUCTION GENERALE.....13

1. PROBLEMATIQUE DE DETECTION ET DE POURSUITE DE CIBLES 19

1.1 Introduction20

1.2 La théorie du radar.....21

1.2.1 Le principe du radar21

1.2.2 Les mesures Radar.....22

1.2.3 L'équation Radar23

1.2.4 La surface équivalente radar.....24

1.2.5 La furtivité radar.....25

1.3 Théorie de la détection.....25

1.3.1 Détection classique.....25

1.3.1.1 Principe de taux de fausses alarmes constant (TFAC) 26

1.3.2 Les méthodes de traitement du signal pour la détection de cibles furtives27

1.3.2.1 Détection par la méthode du maximum de vraisemblance /Filtrage adapté 28

1.3.2.2 Détection adaptative..... 29

1.3.2.3 Détection séquentielle 30

1.4 Extraction et seuillage.....31

1.5 Algorithmes de poursuite de cibles classiques.....32

1.5.1 Objectifs de la poursuite de cibles32

1.5.2 Algorithmes de poursuite mono-cible classique.....33

1.5.3 Algorithmes de poursuite multi-cibles classiques35

1.6 L'approche Track Before Detect36

1.6.1 TBD utilisant la transformation de Hough37

1.6.2 TBD utilisant la programmation dynamique38

1.6.3 TBD utilisant le filtrage particulaire (Noncellular TBD)38

1.7 Conclusion.....39

2. LE FILTRAGE BAYESIEN 40

2.1 Introduction41

2.2 Processus markovien et modèle d'état.....41

2.3 Equation du filtrage non-lineaire43

2.4 Algorithmes Bayésiens récursifs exacts (optimaux).....45

2.4.1 Modèle de Markov caché (HMM).....45

2.4.2 Filtre de Kalman (KF)45

2.5	Algorithmes Bayésiens récurrents sous-optimaux	47
2.5.1	Filtre de Kalman étendu (EKF)	47
2.5.2	Filtre de Kalman sans parfum (UKF)	48
2.5.3	Filtrage particulaire	50
2.6	Estimation multi-modèles	50
2.7	Modélisation des trajectoires de la cible	51
2.7.1	Les modèles non-manouvrants	52
2.7.1.1	Modèle à vitesse constante (CV)	52
2.7.2	Les modèles manouvrants avec les coordonnées-découplées	53
2.7.2.1	Modèle à accélération constante (CA) (Wiener-Process Acceleration Model)	54
2.7.3	Les modèles manouvrants du mouvement horizontal à 2-D	55
2.7.3.1	Modèle de virage (CT) avec taux de rotation connu	56
2.8	Conclusion	57
3.	LE FILTRAGE PARCULARE	58
3.1	Introduction	59
3.2	La méthode de Monte-Carlo	59
3.3	L'échantillonnage de Monte-Carlo standard	60
3.3.1	L'échantillonnage de Monte-Carlo pondéré (échantillonnage d'importance)	61
3.4	L'échantillonnage d'importance séquentiel (SIS)	62
3.4.1	Dégénérescence de l'algorithme SIS	64
3.5	Ré-échantillonnage	65
3.6	Filtrage particulaire générique	67
3.7	Choix de la densité d'importance sous-optimale	69
3.8	Versions du filtrage particulaire	70
3.8.1	Le filtre particulaire SIR (Ré-échantillonnage Séquentiel par Importance des Échantillons)	70
3.8.2	Filtre particulaire auxiliaire (ASIR)	71
3.8.3	Le filtre particulaire régularisé (RPF)	73
3.8.4	Filtre particulaire à modèle multiple (MMPF)	75
3.9	Conclusion	77
4.	L'APPROCHE TRACK-BEFORE-DETECT MONO-CIBLE	78
4.1	Introduction	79
4.2	L'approche TBD mono-cible	80
4.2.1	Le modèle d'état	80
4.2.2	La matrice de transition	80
4.2.3	Le modèle de mesures	81
4.2.3.1	Modèle de mesures image	81
4.2.3.2	Modèle de mesures radar	82
4.2.4	La solution bayésienne de filtrage Track Before Detect	83
4.2.4.1	Prédiction	84
4.2.4.2	Mise à jour (Correction)	84
4.2.4.1	La fonction de vraisemblance pour les mesures images	85
4.2.4.2	La fonction de vraisemblance pour les mesures radar	85

4.2.5 Implémentation de filtre particulaire	87
4.1 Simulations et commentaires de l'algorithme PF-TBD (Les mesures Images)	89
4.1.1 Cible non-manouvrante	89
4.1.1.1 Scénario 1 (Modèle CV)	89
4.1.2 Cible manouvrantes	92
4.1.2.1 Scénario 1 (Modèle CT)	92
4.1.2.1 Scénario 2 (Modèle CA)	94
4.2 Simulations et commentaires de l'algorithme PF-TBD (les mesures Radar)	96
4.2.1 Cible manouvrantes	97
4.2.1.1 Scénario 1 (Modèle CT)	97
4.2.1.2 Scénario 2 (Modèle CA)	100
4.3 Conclusion	102
5. L'APPROCHE TRACK-BEFORE-DETECT MULTI-CIBLE	103
5.1 Introduction	104
5.2 L'approche TBD multi-cible	104
5.2.1 Le Modèle d'état multi-cibles	104
5.2.2 Matrice de transition	106
5.2.3 Modèle de mesure utilisant les données image	106
5.2.3.1 Modèle de mesures image	106
5.2.3.2 Modèle de mesures radar	107
5.2.4 TBD multi-cible à modèle multiple (Multiple Mode Multiple Target TBD)	108
5.2.4.1 Densité à posteriori pour l'algorithme multi-cible à model multiple	108
5.2.4.2 La fonction de vraisemblance pour les mesures image	109
5.2.4.3 La fonction de vraisemblance pour les mesures radar	110
5.2.4.4 La prédiction de l'algorithme MM-MT-TBDF	110
5.2.4.5 Calcul des FDP conjointe de mélange des poids dans MM-MT-TBDF	111
5.2.4.6 Calcul des modes de probabilités pour l'algorithme MM-MT-TBDF	111
5.2.5 Implémentation de filtre particulaire pour l'algorithme MM-MT-TBDF	112
5.2.5.1 L'Algorithme MM-MT-TBDF-PF	113
5.3 Simulation et commentaires de l'algorithme MM-MT-TBDF-PF (les mesures Images)	116
5.4 Simulation et commentaires de l'algorithme MM-MT-TBDF-PF (les mesures radar)	117
5.5 Conclusion	119

CONCLUSION ET PERSPECTIVES

ANNEXE I

PRODUCTION SCIENTIFIQUE

BIBLIOGRAPHIE

LISTE DES FIGURES

Figure 0-1 Poursuite de cibles dans le bruit (cible furtives)	
Figure 1-1 De l'approche classique vers l'Approche Track-Before-Detect.....	20
Figure 1-2 Configuration d'observation d'un Radar.....	21
Figure 1-3 Configuration d'observation d'un radar.....	23
Figure 1-4 Une mesure radar.....	23
Figure 1-5 Surface équivalente radar [53].....	24
Figure 1-6 Exemples de cibles furtives.....	25
Figure 1-7 Relation entre Pfa , Pd et le seuil γ	27
Figure 1-8 Détection adaptative utilisant le filtre adapté.....	30
Figure 1-9 Procédure de détection pour la mesure radar en portée et en azimut.....	31
Figure 1-10 Schéma descriptif des algorithmes classiques de poursuite mono-cible.....	33
Figure 1-11 Schéma descriptif des algorithmes classiques de poursuite multi-cibles.....	36
Figure 1-12 Schéma descriptif des différentes approches TBD.....	37
Figure 2-1 Schéma fonctionnel du modèle de Markov caché.....	43
Figure 2-2 Représentation schématique du modèle d'état.....	43
Figure 2-3 La géométrie du mouvement à 2-D d'une cible.....	55
Figure 3-1 Représentation schématique du ré-échantillonnage systématique [99].....	66
Figure 3-2 Un cycle d'un filtre particulière.....	68
Figure 4-1 Une cible se déplace dans un plan de 2-D.....	81
Figure 4-2 une cible radar avec des mesures en coordonnées polaires.....	82
Figure 4-3 Sélection de six images au sein d'une séquence de mesures à 6.71 dB.....	90
Figure 4-4 Probabilité d'existence pour $RSB=6.71$	91
Figure 4-5 La trajectoire réelle vers la trajectoire estimée à $RSB=6.71$ dB.....	91
Figure 4-6 Les erreurs de position pour différents valeur RSB	91
Figure 4-7 deux images au sein d'une séquence de mesures à 6.71 dB.....	92
Figure 4-8 Probabilité d'existence pour $RSB=6.71$	93
Figure 4-9 La trajectoire réelle vers la trajectoire estimée pour $RSB=6.71$ dB.....	93
Figure 4-10 Les erreurs de position pour différents valeur RSB	93
Figure 4-11 deux images au sein d'une séquence de mesures à 6.71 dB.....	94
Figure 4-12 Probabilité d'existence pour $RSB=6.71$	95
Figure 4-13 La trajectoire réelle vers la trajectoire estimée pour $RSB=6.71$ dB.....	95
Figure 4-14 Les erreurs de position pour différents valeur RSB	96
Figure 4-15 Deux frame de mesures (1,15) : (a) pour $SNR=12$ dB. (b) pour $SNR=3$ dB.....	98
Figure 4-16 La probabilité d'existence de la cible utilisant le modèle CT.....	98

Figure 4-17 La trajectoire réelle vers la trajectoire estimée : (a) faible taux de rotation $2^\circ/s$, (b) taux de rotation levé $130/s$ pour SNR=6dB	99
Figure 4-18 L'erreur de position RMSE pour le filtre PF-TBDF : (a) faible taux de rotation $2^\circ/s$, (b) taux de rotation élevé $13^\circ/s$ à SNR= 6dB	99
Figure 4-19 Frames de mesures (4,15) : (a) pour SNR=12dB (b) pour SNR=6 dB	100
Figure 4-20 La probabilité d'existence de la cible utilisant le modèle CA	101
Figure 4-21 Trajectoire réelle et trajectoire estimée : (a) faible accélération 0.2 ms^{-2} , (b) accélération élevé 5 ms^{-2} à SNR=6dB	101
Figure 4-22 L'erreur de position RMSE pour le filtre PF-TBDF : (a) faible accélération 0.2 ms^{-2} , (b) accélération élevé 5 ms^{-2}	102
Figure 5-1 Indicateur de présence de cible pour $\mathcal{L} = 2$ cibles ($M = 4$ Modes).....	105
Figure 5-2 Six images de la séquence des mesures avec différents modes à RSB=6.71 dB.....	116
Figure 5-3 Probabilité d'existence de deux cibles à un RSB=6.71 dB	117
Figure 5-4 Les trajectoires estimées vers les trajectoires réelle à RSB=6.71 dB	117
Figure 5-5 Quatre mesures avec différent modes à RSB=6.71	118
Figure 5-6 Mode de Probabilité pour l'existence des deux cibles à 6.71 dB	119
Figure 5-7 Les trajectoires estimées vers les trajectoires réelle à RSB =6.71 dB	119

LISTE DES TABLES

Table 3-1 Pseudo code du filtrage par l'algorithme SIS	64
Table 3-2 Pseudo-code du ré-échantillonnage systématique.....	67
Table 3-3 Pseudo-code du filtre particulaire générique.....	68
Table 3-4 Pseudo-code du filtre particulaire SIR	71
Table 3-5 Pseudo-code de filtre particulaire auxiliaire	73
Table 3-6 Pseudo-code de filtre particulaire régularisé RPF.....	75
Table 3-7 Pseudo-code de filtre particulaire générique à modèle multiple MMPF	76
Table 4-1 Filtre particulaire pour Track-Before-Detect (PF-TBD).....	88
Table 5-1 Les étapes de l'algorithme MM-MT-TBDF pour la poursuite multi-cibles	112
Table 5-2 Les étapes de l'algorithme MM-MT-TBDF-PF pour la poursuite multi-cibles.....	115

LISTE DES TABLEAUX

Tableau 1-1 Valeurs typiques de SER mesurées à l'aide d'un radar à onde centimétriques.....	25
Tableau 5-1 Combinaison d'existence des cibles.....	118

ABBREVIATIONS USUELLES

Abréviation	Description
AML	Approximation maximum likelihood
CFAR	Constant false alarm rate
CG	Compound Gaussian
DFT	Discrete Fourier transform
DOA	Discretion of arrival
EKF	Exented Kalman filter
FISST	Finite set statistics
FOV	Field of view
GLRT	Generalized likelihood ratio test
IMM	Interacting multiple model
IP	Independent partition
JPDA	Joint probabilistic data association
KF	Kalman filter
KP	Kronecker Product
LFM	Linear frequency modulated
LQ	Linear quadratic
M-ANMF	M-adaptative normalized matched filter
MCJPDA	Monte Carlo based JPDA
MCMC	Markov Chain monte Carlo
MHT	Multiple hypothesis tracking
ML	Maximum likelihood
MLE	Maximum likelihood estimate
MM-MT-TBDF	Multiple mode multiple target TBDF
MM-MT-TBDF-IP	Independent partition based MM-MT-TBDF
MM-MT-TBDF-IP-MCMC	Independent partition and MCMC based MM-MT-TBDF
MM-MT-TBDF-PF	Particle filter implementation of MM-MT-TBDF
MMPF	Multiple Model Particle Filter
MMSE	Minimum mean-squared error
MSE	Mean-squared error
NKPA	Nearest Kronecker product approximation

NMF	Normalized matched filter
OHGR	Osborne head Gunnery Range
OSPA	Optimal sub-pattern assignment
PCA	Principal Component analysis
PDA	Probabilistic data association
PDF	Probability density function
PF	Particle filter
PF-TBDF	Particle filter based TBDF
PHDF	Probability hypothesis density filter
PHDF-TBDF	Track-before-detect using PHDF
RCS	Radar cross section
RFS	Random finite set
RMSE	Root mean-squared error
Σ -ANMF	Σ -adaptative normalized matched filter
SCR	Signal-to-clutter ratio
SIR	Sampling importance resampling filter
SMC	Sequential Monte Carlo
SNR	Signal-to-noise ratio
TBDF	Track-before-detect filter

INTRODUCTION GENERALE

Motivation

Le développement de systèmes de poursuite radar pour les applications militaires a commencé au début des années 1930 et est devenu un sujet de recherche actif avec le développement du filtre de Kalman (FK) en 1960 [1]. Initialement, la recherche est principalement focalisée sur les systèmes de poursuite de défense aérienne et maritime ainsi que les systèmes de guidage par radar.

Avec les nouveaux progrès en terme de calcul et en capacités de traitement incorporé la technologie radar intervient actuellement dans plusieurs autres domaines tels que le contrôle du trafic aérien pour les vols commerciaux, radar de surveillance météorologique pour localiser les précipitations [2], systèmes radar pour éviter la collision des véhicules [3], le suivi du locuteur dans le traitement de la parole [4], traitement d'image [5], robotique [6], télédétection [7], et la recherche biomédicale [8]. C'est dans ce contexte de développement et de progrès que s'insère la problématique traitée dans ce mémoire. Elle porte particulièrement sur le développement d'algorithmes pour l'aide à la détection et la poursuite de cibles manouvrantes et non manouvrantes.

Poursuite de cibles

Historiquement, les techniques de Bayes ont été utilisées pour étudier et analyser la poursuite de cibles dans le bruit suivant la formulation du modèle d'état [9]. Le filtre de Kalman (KF) présente une estimation optimale des paramètres d'état pour les modèles linéaires dans lequel la mesure et la modélisation des processus aléatoires d'erreur sont supposés être gaussiens [10]. Le filtre alpha-bêta est un dérivé du filtre de Kalman (FK) simple sur le plan de calcul qui a été utilisé avec succès pour estimer la position et la vitesse d'une cible mobile [11][12]. Comme le FK est optimal uniquement pour les modèles à espace d'état linéaires et gaussiens, l'efficacité de poursuite des filtres FK et alpha-bêta n'est pas optimale pour les modèles non linéaires et non gaussiens. Avec le filtre de Kalman étendu (FKE), la transition d'état et les modèles d'observation ne doivent pas nécessairement être des fonctions linéaires de l'état cible, mais, différentiables, de sorte qu'ils peuvent être linéarisés à l'estimation actuelle en utilisant des approximations de la série de Taylor [13]. Une nouvelle classe de simulation basée sur des algorithmes qui comprennent le filtre particulaire (FAP) ou les méthodes séquentielle Monte Carlo (SMC) [14][15] ont évolué à la fin des années 1990, ces algorithmes peuvent être utilisés pour les modèles d'état à distribution non linéaires et non gaussiennes.

Poursuite de cibles dans le bruit

La poursuite de cibles est un problème complexe qui nécessite de prendre en compte plusieurs signaux et conditions ambiantes pour des solutions pratiques [9][16][17]. Par exemple, le signal radar réfléchi d'une cible militaire faiblement observée comme montré dans la Figure 0-1 est d'intensité très faible. Sous les conditions d'un rapport signal sur bruit (SNR) faible, il est possible de manquer la détection des signaux valables à partir des cibles existantes.

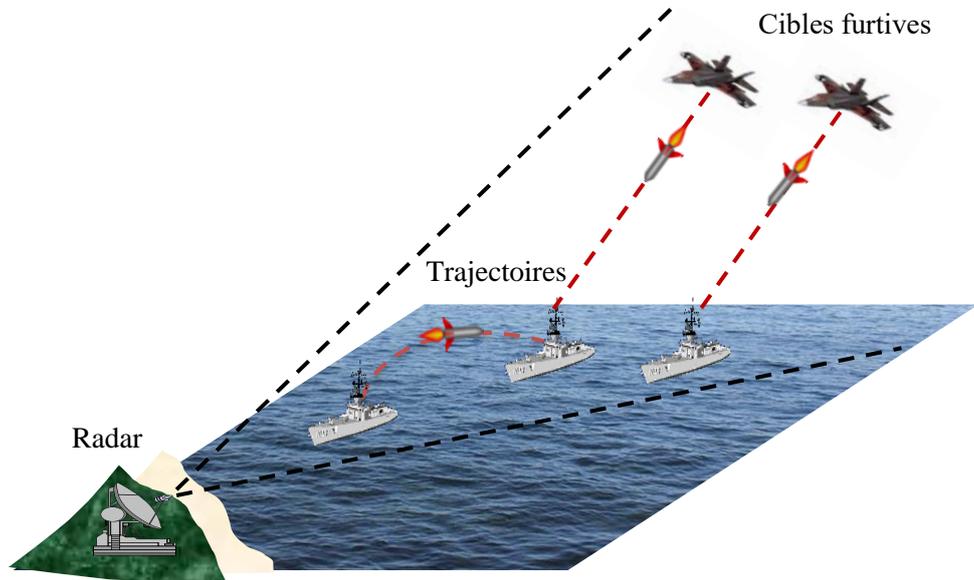


Figure 0-1 Poursuite de cibles dans le bruit (cibles furtives)

Cependant, un système de poursuite devrait pouvoir être capable d'estimer les paramètres d'état de la cible lorsqu'une mesure (un signal ou un écho) provient d'une cible réelle faible. Les fausses alarmes telles que le bruit, le fouillis sont communs dans les systèmes réels, peuvent également compliquer le traitement. Le fouillis dans un espace de mesure réaliste peut causer une incertitude sur l'origine de la mesure. Ceci est un problème d'association des données, puisque l'incertitude rend difficile d'associer la mesure correspondante à la cible réelle. La mesure d'origine incertaine augmente encore par la présence de plusieurs cibles. Dans ce scénario, il est indispensable que les mesures de toutes les cibles possibles soient associées avec les cibles correspondantes en plus d'élaguer (to pruning) les mesures qui proviennent du fouillis. En outre, dans de nombreux cas pratiques réels, le nombre de cibles présentes dans l'espace de mesure d'un système de poursuite n'est pas connue a priori. Ainsi, un système de poursuite de cible ne doit pas seulement être capable de suivre la trajectoire de cibles mobiles mais aussi d'estimer le nombre de cibles qui sont présentes à chaque période ou pas de temps. En outre, le nombre de mesures n'est pas généralement le même que le nombre de cibles qui sont présentes dans le champ de surveillance. En plus de ces problèmes, à chaque période ou pas de temps, un traqueur doit également être capable de déterminer si une cible particulière a quitté le champ de surveillance et si une nouvelle cible est entrée.

A chaque instant, plusieurs mesures sont disponibles, et le traqueur doit identifier la mesure associée à la cible à partir de toutes les mesures. Dans les applications réelles concernant la

poursuite de cibles, la source d'une mesure n'est généralement pas connue par un système de poursuite. Par conséquent, le traqueur doit d'abord associer chaque mesure avec sa source correspondante. Ce processus d'association de données est une étape critique dans un système opérationnel de poursuite de cibles et par conséquent, de nombreuses techniques d'association de données ont été proposées dans la littérature [16][18]. L'une des plus simples techniques d'association de données est la méthode du plus proche voisin, qui sélectionne la mesure la plus proche de la piste prévue pour mettre à jour l'état de la cible [19]. Même si le modèle d'espace d'état est supposé linéaire et gaussien, les états cibles estimés ne sont pas optimaux, car la mesure sélectionnée ne provient pas d'une cible.

Piste et séparation (Track and Split) est une technique d'association de données optimale dans laquelle toutes les mesures sont supposées être valides et une nouvelle piste est lancée pour chaque mesure [20]. Cependant, la complexité de calcul de cette technique augmente très rapidement avec le temps, et ceci en raison de la croissance exponentielle de la structure d'arbres, il est impossible pour des applications en temps réel. Une méthode de probabilité basée sur la poursuite d'une cible dans le fouillis a été proposée dans [21]. Dans cette méthode, l'association de données probabiliste (PDA), les états cibles pour toutes les mesures sont estimés séparément en plus de calculer la probabilité d'association de mesure à la cible. L'approche estime l'état cible finale en combinant tous les états cibles possibles pondérés par la probabilité d'association de mesure à cible correspondante [18][22][23]. Une méthode basée sur PF pour suivre une cible dans le fouillis a également été proposé dans [24] pour les modèles d'espace d'état non linéaires / non gaussiennes.

Poursuite Multi-cibles

Le problème de poursuite dans le fouillis mentionné ci-dessus devient extrêmement compliqué quand il y a un nombre multiple de cibles qu'il faut suivre simultanément. Une liste des différentes techniques de poursuite de cibles ainsi qu'une comparaison de leurs performances et de la complexité de calcul est présentée dans [25]. Poursuite à hypothèse multiple (MHT) [26],[27] est une technique de mesure multi-cibles connue dans laquelle on obtient chaque cible établie ou une nouvelle cible qui donne lieu à une séquence de mesure.

La complexité de calcul de cet algorithme peut grandir de façon exponentielle comme l'augmentation de nombre d'hypothèses de piste. On pourrait utiliser des techniques de réduction des hypothèses telles que zéro regroupement (zero scan clustering) ou une hypothèse d'élimination (hypothesis Elimination) pour augmenter la faisabilité de calcul de cet algorithme. Le filtre à association de données par probabilités conjointe (JPDA) [28] est un autre algorithme populaire qui étend (extension) le filtre PDA pour la poursuite multi-cibles. Ceci est un algorithme de balayage à zéro, dans lequel tous les ensembles de mesures courantes sont combinés immédiatement pour fournir une estimation de l'état de la cible. Le filtre JPDA contient toutes les données de mesures et le nombre connu de cibles, toutes les combinaisons possibles de mesure-à-cible (hypothèse) sont formées.

Récemment, l'approche Bayésienne optimale de l'estimation de la fonction de densité de probabilité multi-cibles (PDF) a proposé d'utiliser un ensemble statistique aléatoire limité (fini) (RFS) [29][30]. Cette approche permet de suivre un nombre variables de cibles pour estimer

leurs vecteurs d'état. Néanmoins, deux techniques d'approximation connues avec des implémentations possibles ont été proposées qui rapprochent la PDF multi-cibles soit par la distribution de Poisson [31][32] ou multiples distributions de Bernoulli [33][34]. Le filtre à hypothèse de densité probabilité (PHDF) [31][32] approxime la PDF multi-cibles par une distribution de Poisson qui est souvent (très populaire) utilisée dans la poursuite d'un nombre variable de cibles avec une probabilité de détection non nulle en présence du fouillis (clutter). La version SMC du PHDF pour les modèles non linéaires et non-gaussiens a été initialement proposée dans [30][35].

Le filtre Track before detect (TBDF)

Dans les systèmes radar classiques, la poursuite de cibles mobiles à faible SNR en utilisant les détecteurs à taux de fausses alarmes constant (CFAR) [36] [37] peuvent donner de mauvaises performances. Étant donné que le seuil de détection d'un détecteur CFAR augmente de manière dynamique dans les conditions à faible SNR, la probabilité de détection de cibles est faible pour une cible avec une petite surface équivalente radar [38]. Si le seuil est augmenté pour augmenter la probabilité de détection, puis d'autres mesures sont nécessaires en entrée d'un algorithme de poursuite en raison de l'augmentation du nombre de fausses alarmes. Cette augmentation du nombre de mesures peut augmenter la complexité de calcul exponentiellement de plusieurs algorithmes de poursuite de cible tels que JPDA et MHT. Pour améliorer les performances de poursuite dans des conditions à faible SNR, la méthode de filtre track before detect (TBD) a été proposée car il n'utilise pas de mesures non seuillées. Les algorithmes de TBDF sont basés sur la transformée de Hough [39], la programmation dynamique [40] ou des méthodes du maximum de vraisemblance [41] qui nécessitent généralement des moyens de calcul intensif [15]. Avec la progression récente des techniques SMC, les algorithmes TBDF implémentés utilisant PF sont maintenant réalisables informatiquement [42][43].

Le filtrage Track-Before-Detect Multi-Cibles

La poursuite de plusieurs cibles à faible rapport signal sur bruit (SNR) ou évoluant dans un contexte fortement bruité (fouillis élevé) est un problème difficile. Par exemple, dans les applications de surveillance maritime, il est nécessaire de poursuivre les petits bateaux intrus dans les conditions de la mer turbulente ou dans un système de défense de première alerte (précoce), il est impératif de détecter les cibles les plus lointaines du système radar. Dans ces applications, généralement le SNR est faible, ceci implique que le signal réfléchi par la cible est faible ou le niveau de bruit est très élevé. La poursuite multi-cibles dans telles conditions est un problème extrêmement difficile, car le problème de poursuite est compliqué par plusieurs facteurs tels que l'origine de l'incertitude de mesure, nombre inconnu de cibles, et la faisabilité de calcul.

Différents algorithmes TBDF ont été proposés pour la poursuite à temps variable / nombre fixe des cibles dans des conditions variables. Le PF à cible unique basé sur le TBD [42] a été étendu à suivre deux cibles dans [44] en remplaçant la variable d'état cible d'existence binaire avec une variable de mode à trois états. Les particules correspondant à ce mode de variable sont également propagées au cours du processus de poursuite et la méthode a été illustrée à l'aide d'un exemple restrictif par le suivi d'une deuxième cible qui génère la première cible [44]. En

outre, dans cette méthode, la dimension du vecteur d'état de la cible est fixé au nombre maximum de cibles et la dimension du vecteur d'État n'est pas comptée pour le nombre variable de cibles. En outre, cette méthode ne couvre pas entièrement toutes les possibilités des combinaisons cible morte-cible naissante. Par exemple, il n'y a pas un mécanisme non ambigu pour suivre la trajectoire d'une cible restante après une cible disparue. Les auteurs [45] ont utilisé le TBDF mono-cible de [42] pour suivre plusieurs cibles en gardant la piste d'un certain nombre de pics dans l'estimation de la PDF a posteriori. Le TBDF Multi-cibles pour un radar passif est utilisé dans [46]. En étendant (prolongeant) TBDF récursif mono-cible à chaque domaine range-Doppler avec la probabilité d'existence de la cible et PDF conditionnés sur l'existence de la cible dans chaque domaine.

Plusieurs méthodes PHDF basées sur TBD (PHDF-TBD) et qui sont adaptées pour les modèles de mesure non-linéaires existent dans la littérature. La méthode SMC basée sur PHDF-TBD pour les applications d'image a été introduite dans [47] et a démontré par le suivi de trois cibles. Un filtre multiple de Bernoulli basé sur TBDF avec une étape de gestion de la piste sur la base de l'étiquette séparée a été proposé dans [48] et illustré en utilisant la mesure de l'image pour suivre jusqu'à 4 cibles dans des conditions à SNR élevé. Récemment, la méthode TBD multi-cibles et multi-modes MM-MT-TBDF a été proposée dans [49] pour poursuivre un nombre variable de cibles dans des conditions de faible rapport signal/bruit (SNR) et de faible rapport signal/fouillis (SCR) qui peuvent être mises en œuvre à l'aide de techniques séquentielles de Monte Carlo (SMC). L'algorithme MM-MT-TBDF-PF multi-cibles estime les états cibles sous toutes les combinaisons ou modes d'existence de cibles possibles en utilisant la fonction de densité de probabilité conjointe postérieure de cible multiple dérivée. Cet algorithme (MM-MT-TBDF-PF) peut garder la trace de cibles entrant ou sortant d'une scène, et seul le nombre maximum de cibles sur la durée d'une piste doit être connu.

Les objectifs

Le travail réalisé et présenté dans ce mémoire de thèse a pour objectifs d'étudier et de développer la méthodologie de détection et de pistage radar d'une ou plusieurs cibles. Dans ce contexte, la méthode Track-Before-Detect par filtrage particulière a été étudiée et appliquée en considérant des cibles avec différents types de mouvement.

Organisation du mémoire

Ce mémoire est organisé comme suit : Le premier chapitre est consacré à la présentation de la problématique de détection et la poursuite de cibles, et notamment les cibles furtives. Le deuxième chapitre est consacré à la discussion sur différentes approches permettant l'estimation des paramètres d'état cible tels le filtrage de Kalman et le filtrage particulière. Le troisième chapitre présente les différents algorithmes de filtrage particulière utilisé pour l'approche track before detect. Le quatrième chapitre est dédié d'une part à la présentation de l'approche track before detect utilisant le filtrage particulière pour la poursuite mono-cible. Et d'autre part à la présentation de différentes simulations effectuées en considérant des images ou des signaux radar. Quant au chapitre 5, il est consacré à la problématique de poursuite multi-cibles. Ainsi, nous présentons une étude détaillée de l'algorithme TBD multi-cibles à model multiple basé sur le filtre particulière et l'algorithme MM-MT-TBD pour différents types de trajectoires et

différentes valeurs du rapport signal sur bruit (RSB). Ce chapitre se termine par la présentation, des résultats de simulation accompagnés par des analyses commentées d'une manière comparative. Enfin, ce mémoire dresse un bilan des travaux réalisés via une conclusion générale. Et des perspectives d'études pour améliorer la méthodologie développée sont proposées.

1. PROBLEMATIQUE DE DETECTION ET DE POURSUITE DE CIBLES

1. PROBLEMATIQUE DE DETECTION ET DE POURSUITE DE CIBLES	19
1.1 Introduction	20
1.2 La théorie du radar.....	21
1.2.1 Le principe du radar	21
1.2.2 Les mesures Radar.....	22
1.2.3 L'équation Radar.....	23
1.2.4 La surface équivalente radar.....	24
1.2.5 La furtivité radar.....	25
1.3 Théorie de la détection.....	25
1.3.1 Détection classique.....	25
1.3.1.1 Principe de taux de fausses alarmes constant (TFAC)	26
1.3.2 Les méthodes de traitement du signal pour la détection de cibles furtives.....	27
1.3.2.1 Détection par la méthode du maximum de vraisemblance /Filtrage adapté	28
1.3.2.2 Détection adaptative.....	29
1.3.2.3 Détection séquentielle	30
1.4 Extraction et seuillage.....	31
1.5 Algorithmes de poursuite de cibles classiques.....	32
1.5.1 Objectifs de la poursuite de cibles	32
1.5.2 Algorithmes de poursuite mono-cible classique.....	33
1.5.3 Algorithmes de poursuite multi-cibles classiques	35
1.6 L'approche Track Before Detect	36
1.6.1 TBD utilisant la transformation de Hough	37
1.6.2 TBD utilisant la programmation dynamique	38
1.6.3 TBD utilisant le filtrage particulaire (Noncellular TBD)	38
1.7 Conclusion.....	39

Ce chapitre est consacré à la présentation de la problématique de détection et de poursuite de cibles radar, en considérant en particulier les cibles furtives. Ainsi, nous avons présenté quelques généralités sur l'état de l'art concernant la détection et la poursuite classique de cibles. Ensuite, nous avons présenté les bases de la problématique de l'approche track-before-detect et les différentes méthodes classiques utilisées dans la littérature.

1.1 Introduction

Le rôle du pistage de cibles est avant tout d'assurer la cohérence temporelle des observations afin d'éviter les fausses alarmes et de filtrer l'état. La structure de haut niveau d'un tel système est donnée par la Figure 1-1. Cette figure illustre deux approches utilisées dans le système de poursuite radar. La première est la méthode classique, la deuxième concerne une nouvelle méthode récemment proposée. Il s'agit de l'approche Track-Before-Detect qui constitue le cœur du travail réalisé et présenté dans ce mémoire.

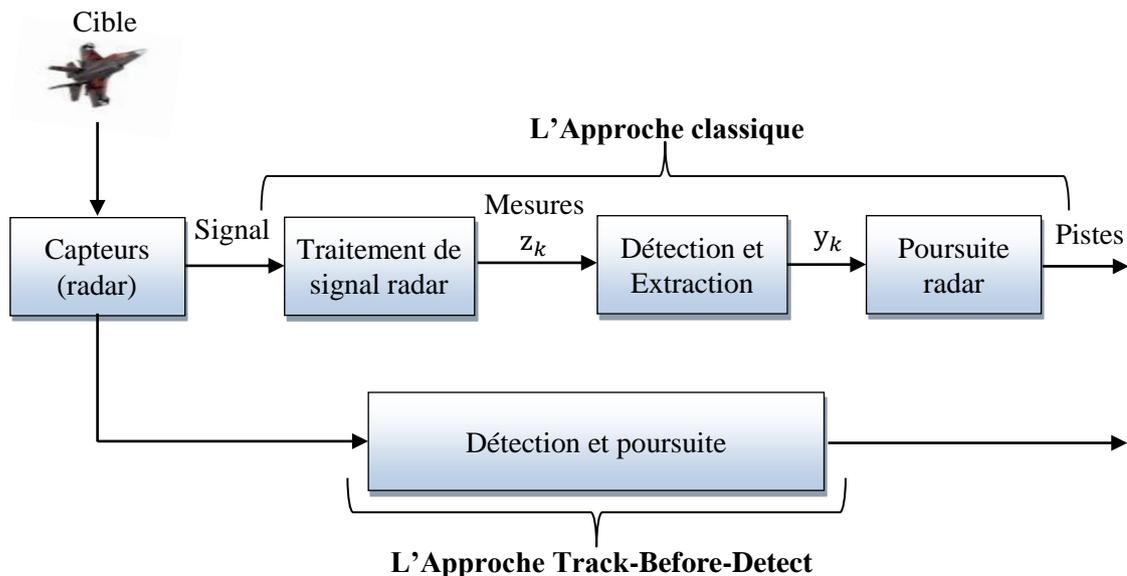


Figure 1-1 De l'approche classique vers l'Approche Track-Before-Detect

Les capteurs (comme les radars) délivrent des signaux qui sont collectés par un module de traitement du signal. Ce module a en particulier pour but d'améliorer le rapport signal sur bruit (RSB) de la cible, et permettant ainsi de détecter et d'estimer les paramètres de cibles (tels que la portée, la vitesse radiale, l'azimut,...). Dans la chaîne radar classique, le bloc de "traitement du signal radar" fournit une mesure z_k comme entrée pour la "détection et l'extraction des pics (hits)". L'étape suivante consiste d'abord à seuiller les mesures radar z_k , puis extraire les paramètres des cibles probables de tout échantillon de signal (appelé pic "hit") ayant passé le seuil de détection. A la fin de cette étape, un ensemble de résultats de détection y_k est fourni à l'étape de poursuite. Cette dernière étape tire parti de certaines informations sur le mouvement de la cible (par exemple le type de trajectoire) pour améliorer l'estimation des paramètres cibles dans le temps. De plus, il permet de discriminer dans le temps les "hits" qui proviennent de cibles par rapport à ceux qui sont dus à de fausses alarmes afin de former des pistes.

Dans la pratique, l'étape "détection et extraction des pics (hits)" permet de réduire considérablement la quantité de données à traiter, en effet la taille de la mesure z_k peut être très importante (c'est un tableau multidimensionnel pouvant contenir plusieurs dizaines de milliers de cellules) alors que, si le seuil est choisi de manière pratique pour limiter les fausses alarmes, l'ensemble y_k est beaucoup plus petit, mais en retour, certaines informations sont perdues, ce qui peut être préjudiciable, surtout si certaines cibles ont un faible rapport signal sur bruit. Une

nouvelle approche, connue sous le nom de Track-Before-Detect, a donc été proposée et consiste à effectuer conjointement la détection et la poursuite à partir de la mesure z_k plutôt qu'à partir de l'ensemble des pics "hits" de détection, comme l'illustre la Figure 1-1. Comme indiqué précédemment, cet algorithme TBD combinant la poursuite et la détection constitue le cœur de cette thèse.

Avant d'aller plus loin dans les détails de la stratégie Track-Before-Detect, nous proposons d'abord dans ce chapitre de présenter quelques aspects et notions sur la théorie de détection. Ainsi, nous présentons tout d'abord des notions sur la détection de cibles à faible rapport signal sur bruit, en suite quelques détails sur la poursuite de cibles sont indiquées, et pour finir, les variantes classiques de l'approche Track-Before-Detect utilisées dans la littérature sont présentées.

1.2 La théorie du radar

1.2.1 Le principe du radar

Un radar (Radio Detection and Ranging) est un système qui est basé sur la propagation des ondes électromagnétiques et il est globalement constitué d'une antenne pour transmettre un signal avec une forme d'onde particulière, ainsi que de recevoir et de détecter le signal rétrodiffusé par tout diffuseur présent dans le champ de surveillance. Un tel diffuseur peut être une ou plusieurs cibles (comme les avions, les navires, etc.). Ce principe est illustré par la figure 1-2. Puis en mesurant la durée τ du trajet aller-retour entre le radar et la cible, il est possible de calculer la portée r avec l'équation suivante :

$$r = \frac{ct}{2} \quad (1.1)$$

où c est la vitesse de la lumière. Le mouvement de la cible cause un décalage fréquentiel entre le signal émit et le signal reçu : c'est ce qu'on appelle l'effet Doppler. Le décalage de fréquence entre le signal émit et le signal reçu est approximativement égal à $\frac{2\dot{r}}{c} f_0$ où f_0 est la fréquence du signal émit et \dot{r} la vitesse radiale. Par conséquent, en mesurant l'effet Doppler, il est possible d'extraire la vitesse radiale de la cible.

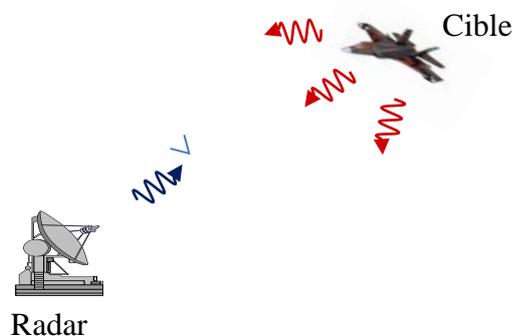


Figure 1-2 Configuration d'observation d'un Radar

Cette description succincte constitue le principe général du radar. Cependant, dans la pratique, la mesure du retard et la mesure de l'effet Doppler n'est pas aussi simple. En effet, le signal transmis sera atténué et seule une partie de l'énergie rétrodiffusée sera réfléchi par la cible dans la direction du radar. Par conséquent, le signal reçu par une chaîne de réception complète permet de récupérer le signal atténué avec un certain bruit additif. Deux questions peuvent alors être posées :

- Es que le signal reçu se compose d'une ou plusieurs contributions cibles ou uniquement du bruit ?
- Comment faire une bonne estimation du retard de l'onde et des paramètres Doppler lorsque le signal reçu est corrompu par le bruit ?

La première question correspond au problème de détection ; la théorie de la détection [50], pratiquement la résolution de ce problème dans le contexte radar par les critères de Neyman-Pearson ; c'est-à-dire maximiser la probabilité de détection de signal (s'il est présent) tout en assurant une probabilité de fausse alarme donnée. Dans de nombreuses applications, particulièrement en radar, cette procédure de détection utilise le filtre adapté (matched filter) [51].

La deuxième question correspond au problème d'estimation qui est souvent résolu à l'aide des critères du maximum de vraisemblance, c'est-à-dire trouver la valeur du paramètre qui maximise la probabilité que le signal se produise avec la valeur du paramètre correspondant. Pratiquement, cette maximisation conduit souvent à trouver la sortie maximale du filtre adapté et est fortement liée aux caractéristiques du signal transmis (en particulier la durée et la bande passante de fréquence).

Le radar a joué un rôle très important pour améliorer la qualité d'image grâce à toutes ses performances et sa capacité de mesurer les coordonnées cinématiques dans différents domaines tel que le contrôle de trafic aérien (ATC), la surveillance, la poursuite de cibles, la navigation maritime, ...etc.

1.2.2 Les mesures Radar

La Figure 1-3 montre une configuration standard d'observation d'un radar classique. La portée r est la distance entre le radar et la cible. L'angle d'élévation ϕ est l'angle entre le plan horizontal et la direction du radar. L'angle de relèvement θ est la rotation autour de l'axe des z donne une référence, ici l'axe des x .

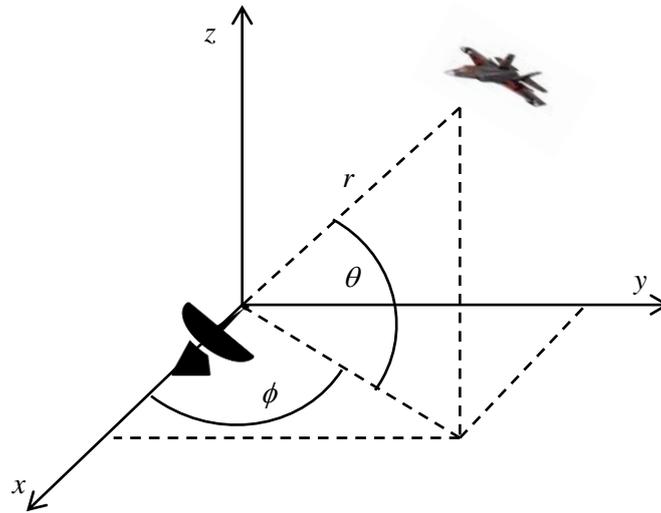


Figure 1-3 Configuration d'observation d'un radar

La transformation de l'angle d'élévation et de la portée mesurées par le radar en coordonnées cartésiennes est donnée par :

$$x = r \cos \theta \cos \phi \quad (1.2)$$

$$y = r \cos \theta \sin \phi \quad (1.3)$$

$$z = r \sin \theta \quad (1.4)$$

Une mesure de la puissance reçue en fonction de la distance et la vitesse (Doppler) est présentée par la Figure 1-4. Le pic élevé correspond à l'énergie réfléchié par la cible plus le bruit.

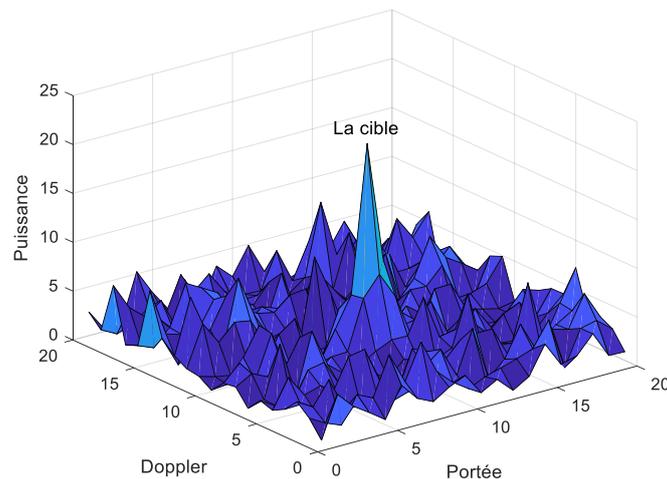


Figure 1-4 Une mesure radar

1.2.3 L'équation Radar

L'équation radar donnée dans [52] résume le bilan de puissance pendant la propagation des ondes entre un émetteur et un récepteur (Cf. figure à ajouter en liaison bistatique). Ce bilan

énergétique exprime en configuration bistatique, la puissance reçue par le récepteur en fonction de la puissance émise et les paramètres du système :

$$P_r = \frac{P_T G_T F_T G_R F_R \lambda^2 \sigma_e}{(4\pi)^3 \mathcal{L}_T \mathcal{L}_R (R_T R_R)^2} \quad (1.5)$$

Avec :

- P_T : puissance émise.
- P_r : puissance reçue.
- G_T : gain de l'antenne émettrice.
- F_T : diagramme de transmission de l'antenne émettrice.
- G_R : gain de l'antenne réceptrice.
- F_R : diagramme de transmission de l'antenne réceptrice.
- λ : longueur d'onde de propagation.
- \mathcal{L}_T : perte (>1) sur le chemin émetteur-cible.
- \mathcal{L}_R : perte (>1) sur le chemin cible-récepteur.
- σ_e : surface équivalente radar de la cible.

1.2.4 La surface équivalente radar

La surface équivalente radar (SER) nommée aussi surface efficace radar ou (Radar Cross Section (RCS), en anglais) est une propriété physique inhérente des objets indiquant l'importance relative de la surface de réflexion d'un faisceau électromagnétique qu'ils provoquent. La surface équivalente radar est fonction de la forme de l'objet, de la nature de ses (ses) matériaux (x) constitutif (s), ainsi que de la longueur d'onde et des angles d'incidence et de réflexion du rayonnement.

La SER est un paramètre physique important d'un objet quelconque présent dans le champ de surveillance (véhicule, avion ou navire) influant fortement sur sa sensibilité d'être détecté par un radar. La caractéristique d'une SER faible est une qualité importante pour les cibles militaires, ceci lui permet notamment de ne pas être détectée par un radar adverse. Il existe des technologies de furtivité très avancées qui ont été mises au point dans le but de réduire la SER d'une cible et/ou d'un objet. En général la SER d'un objet sensible est généralement considéré comme un secret militaire et par conséquent il n'est pas divulgué.

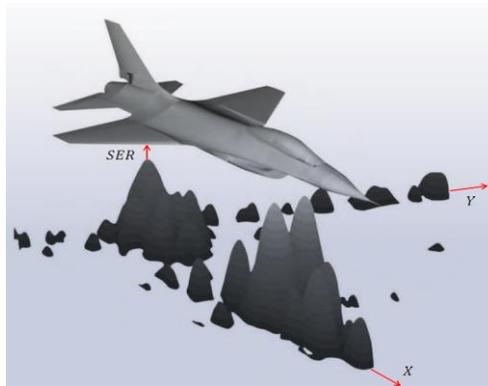


Figure 1-5 Surface équivalente radar [53]

La mesure de la surface équivalente d'un objet se fait par le radar. Cette mesure peut se réaliser en plein air ou dans une chambre anéchoïque équipée.

1.2.5 La furtivité radar

La furtivité radar s'exprime en générale par une valeur correspondant à la surface équivalente SER ; celle-ci correspond en fait à la valeur de la surface de l'objet détectée par le radar. L'objectif principal de la furtivité radar est de réduire la SER de la cible (avion, navire, missile...ect).



© <http://tpe-la-furtivite.e-monsite.com/http-tpe-la-furtivite-e-monsite-com-/la-furtivite/ii-la-furtivite.html>

Figure 1-6 Exemples de cibles furtives

Par exemple dans le cas d'un avion militaire furtif ou un navire équipé de technologies particulières et d'une forme spécifique, peut avoir une SER de l'ordre du mètre carré, et même moins. Il est même possible d'amener un avion à posséder une SER équivalente à celle d'un oiseau ou encore d'un bourdon. Dans cette thèse on s'intéresse aussi à la détection et la poursuite de cibles à faible SER.

Cibles furtives	SER (m ²)
Avions furtifs	0,01 à 0,02m ²
Missiles anti-aériens	Environ 0,1m ²
Avion de chasse	0,1à 1m ²
Bombardiers	1 à 2m ²
Avion de transport lourd	Jusqu'à 50 m ²
Avion commerciaux civils	Jusqu'à 50 m ²

Tableau 1-1 Valeurs typiques de SER mesurées à l'aide d'un radar à onde centimétriques

1.3 Théorie de la détection

1.3.1 Détection classique

La fonction première d'un radar est la détection d'une cible et l'estimation de sa distance. Parmi les éléments qui peuvent perturber cette détection, on peut noter le fouillis, le bruit du récepteur et le brouillage qui sont considérés comme des variables aléatoires évoluant dans le temps. Par exemple, si nous ne pouvons pas donner la valeur exacte de la puissance du fouillis, alors nous pouvons donner la distribution statistique du fouillis, celle du brouillage et celle du bruit thermique du récepteur. De la même manière, les fluctuations de l'amplitude de la cible sont considérées comme des variables aléatoires, en considérant les modèles de Swerling [54]. La nature aléatoire de l'environnement et du signal radar peuvent causer une ambiguïté quant

à savoir l'état de la cible si elle est présente ou non. L'objectif de l'étude de la théorie de détection radar est de trouver une méthode raisonnable pour déterminer de manière statistique, laquelle des deux hypothèses possibles (cible présente ou cible absente) permet de générer une observation donnée. Dans ce sens, la théorie de la détection basée sur les tests d'hypothèses permet d'apporter certaines réponses à cette problématique.

On fixe une case d'analyse (case distance-Doppler), le vecteur d'observation z est bruité par un bruit additif v . La formulation du problème de détection est donnée par l'expression suivante :

$$\begin{cases} H_0: z = v \\ H_1: z = z + v \end{cases} \quad (1.6)$$

Où z est le signal d'observation qui caractérise la cible. H_0 correspond à l'hypothèse de l'absence de la cible et dans ce cas le radar reçoit un signal complexe z ne contenant que les échos indésirables comme le fouillis ou le bruit (du type bruit thermique). Ces parasites peuvent être caractérisés par une densité de probabilité notée par p_v ainsi que par la densité de probabilité du signal reçu qui est donnée par $p_y(z|H_0) = p_v(z|H_0)$.

L'hypothèse H_1 correspond au cas de la présence de la cible, le signal z reçu par le radar provenant des échos de la cible plus les parasites considérés sous l'hypothèse H_0 . La densité de probabilité de signal reçu dans ce cas est donnée par $p_y(z|H_1)$.

Donc la théorie de détection a pour objectif de déterminer laquelle de ces deux hypothèses est la plus vraisemblable, en utilisant la minimisation des deux erreurs suivantes [52]:

- Choisir H_0 Alors que H_1 est vraie. Dans ce cas, on parle de la non-détection, avec la probabilité $P_{nd} = P(H_0|H_1) = 1 - P(H_1|H_1) = 1 - P_d$, où P_d représente la probabilité de détection.
- Choisir H_1 Alors que H_0 est vraie. Dans ce cas, on parle de fausses alarmes, avec la probabilité $P_{fa} = P(H_1|H_0)$.

1.3.1.1 Principe de taux de fausses alarmes constant (TFAC)

Dans le cas des signaux réels, il est difficile de s'affranchir totalement de ces erreurs, sauf dans le cas où on connaît très bien la statistique de l'environnement radar et le type de la cible à détecter. Le critère de Neymann-Pearson donne un bon compromis pour le but de maximiser la probabilité de détection P_d pour une certaine valeur de fausses alarmes $P_{fa} = \alpha$. Pratiquement cette valeur est donnée par l'utilisateur, généralement c'est une très faible valeur. Cette méthode est nommée par le principe de taux de fausses alarmes constant (TFAC) (Constant False Alarm Rate « CFAR » en anglais) [55]. Le test du rapport de vraisemblance est donné par :

$$\Lambda(z) = \frac{p_z(z|H_1)}{p_z(z|H_0)} \underset{H_0}{\overset{H_1}{\geq}} \gamma \quad (1.7)$$

On l'appelle aussi le test optimal selon le critère de Neymann-Pearson. Le seuil de détection γ est déterminé pour fixer la probabilité de fausses alarmes $P_{fa} = \alpha$, et ce calcul est fait à partir de la résolution de l'équation suivante :

$$P_{fa} = \int_{D_1} p_z(z|H_0) dz \quad (1.8)$$

où D_1 est l'ensemble des mesures z contenues dans le domaine de décision de l'hypothèse H_1 . Souvent c'est difficile de trouver une formulation analytique de ces équations, et on détermine le seuil γ soit par la résolution de l'équation (1.7), soit par les méthodes de Monte-Carlo.

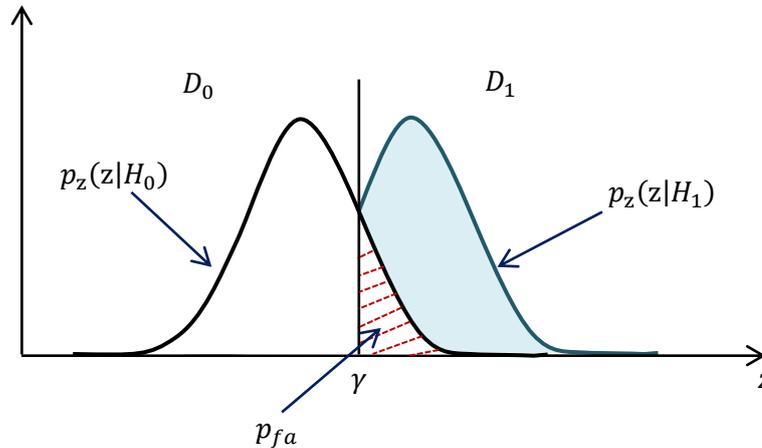


Figure 1-7 Relation entre P_{fa} , P_d et le seuil γ

Après la détermination du seuil, on peut calculer la probabilité de fausses alarmes P_{fa} de la manière suivante :

$$P_d = \int_{D_1} p_z(z|H_1) dz \quad (1.9)$$

Comme les formules précédentes, c'est souvent difficile de trouver une expression analytique de la probabilité de détection P_d .

Pour le cas d'un bruit blanc gaussien de variance N_v , soit $v \sim \mathcal{N}(0, N_v)$, on obtient :

$$P_{fa} = P\{|z| > \gamma | H_0\} = P\{|v| > \gamma\} = e^{-\left(\frac{\gamma^2}{N_v}\right)} \quad (1.10)$$

1.3.2 Les méthodes de traitement du signal pour la détection de cibles furtives

Plusieurs raisons importantes expliquent le besoin croissant de la détection dans les environnements fortement bruités (ou la détection de cibles de faible SER ou de faible rapport signal sur bruit). Tout d'abord on peut noter le développement récent et croissant de cibles militaires furtives ainsi que l'intérêt de détecter et suivre d'autres petites cibles comme les missiles, les petits avions et bateaux utilisés pour le trafic de drogue. La détection de ce genre de cibles de faible rayonnement ou de faible SER est améliorée en diminuant les seuils de détection ou en augmentant la sensibilité du capteur. Ces deux options créent la nécessité de traiter un grand nombre de fausses alarmes. Par exemple, la sensibilité des systèmes radar modernes est telle que les oiseaux et même les abeilles peuvent être détectés [56]. Cette partie présente les principes de base des techniques du traitement du signal utilisées pour la détection de cibles à faible rapport signal sur bruit (cibles furtives) pour le radar et les capteurs infrarouges.

1.3.2.1 Détection par la méthode du maximum de vraisemblance /Filtrage adapté

La technique du maximum vraisemblance est basée sur l'estimation des fonctions de densité de probabilité (PDF) d'un signal reçu dans les conditions de présence ou d'absence d'une cible. Les données du signal reçu sont utilisées dans la fonction de densité de probabilité (PDF) pour former le rapport de vraisemblance et de calculer son logarithme. Enfin, le rapport de vraisemblance est utilisé pour définir une valeur statistique y qui est comparée à un seuil choisi d'une manière appropriée pour déterminer si une détection peut être déclarée ou non. Ce seuil est choisi en fonction d'une probabilité de fausses alarmes (P_{fa}).

Nous définissons z comme étant un vecteur de mesures avec N éléments. H_1 et H_0 sont respectivement l'hypothèse de la présence et l'absence de la cible, de telle sorte que la fonction de densité de probabilité $p(z|H_i)$ des mesures z donne l'hypothèse H_i .

Ensuite, nous supposons des distributions gaussiennes avec un signal moyen égal à As sachant que R est la matrice de covariance le bruit de fond (ou fouillis) de dimension $(N \times N)$. Le vecteur s définit la forme du signal de la cible et A est l'amplitude inconnue du signal. Par exemple, pour le traitement infra-rouge (IR), s représente la forme spatiale de signal réfléchi par la cible telle qu'elle est donnée par la fonction d'étalement ponctuelle du capteur. Ensuite, le rapport du maximum vraisemblance de la présence (l'hypothèse H_1) et l'absence (l'hypothèse H_0) de la cible est donné par :

$$\Lambda(z) = \ln \left[\frac{p(z|H_1)}{p(z|H_0)} \right] = \ln \left[\frac{\exp \left[-\frac{(z-As)^T R^{-1} (z-As)}{2} \right]}{\exp \left[-\frac{z^T R^{-1} z}{2} \right]} \right] = (z^T R^{-1} As + As^T R^{-1} z - As^T R^{-1} As) / 2 \quad (1.11)$$

Pour déclarer l'hypothèse H_1 (cible présente), la valeur calculée de $\Lambda(z)$ donnée par (1.10) et testée par rapport à un seuil. Notant que $s^T R^{-1} s$ est une constante, en tenant compte de l'amplitude inconnue A du signal s et en définissant

$$z^T R^{-1} s = z^T R^{-1} z = y \quad (1.12)$$

Ce test devient

$$y \geq \gamma; \text{ déclare la cible présente} \quad (1.13)$$

La pondération du vecteur de mesures z par $s^T R^{-1}$ pour former le test statistique y est connue sous le nom de filtre adaptatif (matched filter). Cette pondération peut également être obtenue en supposant une forme générale.

$$y = h^T z \quad (1.14)$$

Et résoudre le problème pour la valeur h qui maximise le RSB de sortie [57].

La procédure de traitement infrarouge IR standard consiste d'abord à supprimer la moyenne locale pour que le fouillis (bruit) ait une moyenne nulle. Ensuite, en l'absence de signal, la statistique y a une moyenne et une variance nulle:

$$\sigma_z^2 = E[y^2|H_0] = s^T R^{-1} E[zz^T] R^{-1} s = s^T R^{-1} s \quad (1.15)$$

Si la cible est présente, la valeur prévue de y est, en remplaçant z dans l'équation (1-2) par sa valeur prévue As

$$E[y|H_1] = As^T R^{-1} s \quad (1.16)$$

Ainsi, le RSB de sortie est donné par

$$RSB = \left[\frac{E[y|H_1]^2}{\sigma_y^2} \right]^{1/2} = A[s^T R^{-1} s]^{1/2} \quad (1.17)$$

Enfin, l'expression de σ_z^2 donnée par la formule (1.14) en précisant une probabilité de fausses alarmes P_{fa} acceptable, le seuil γ utilisé dans l'équation (1.12) est déterminé à partir d'une distribution gaussienne comme suit

$$P_{fa} = \int_{\text{TH}}^{\infty} \exp[-y^2/\sigma_y^2] dy \quad (1.18)$$

1.3.2.2 Détection adaptative

Les techniques de détection présentées précédemment s'appliquent au cas idéal où la distribution du bruit de fond est supposée (ou fouillis) connue. Dans la pratique, généralement les distributions du bruit de fond ne sont pas connues a priori. Ainsi, un processus conjoint d'estimation et de détection est utilisé dans le cadre où les distributions du fond sont estimées avant la détection des cibles. Cette section donne un bref aperçu de ces approches.

La Figure (1-7) montre la logique d'un algorithme adaptatif de détection de filtre adapté dans lequel les données d'entrée z_{in} , sont les intensités sur une cellule (a grid) de N pixels pour un système IR. L'exemple de l'IR est développé ici, mais une analogie radar prendrait en compte les récepteurs Doppler. Dans le cas d'un système IR fonctionnant sur un fond nuageux, il y aurait généralement un algorithme de segmentation fonctionnant sur l'ensemble du champ de données [58], de sorte que le traitement illustré dans la Figure (1-8) serait effectué pour chaque segment.

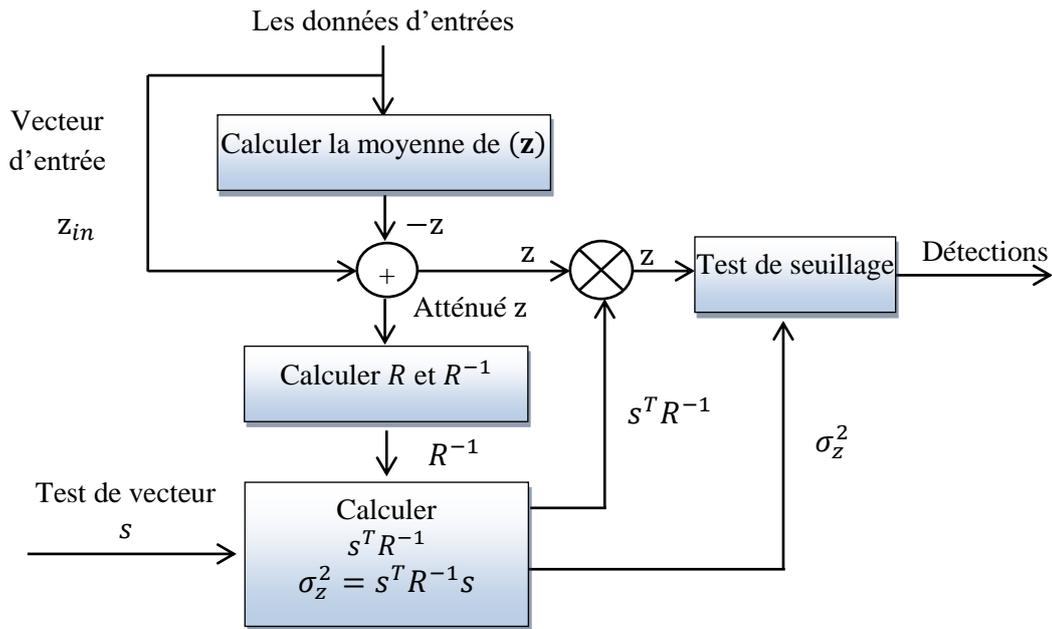


Figure 1-8 Détection adaptative utilisant le filtre adapté

La Figure (1-8) montre un traitement adaptatif typique commençant par le calcul de la moyenne et la covariance de fond pour un ensemble d'entrées de N point de données. Lorsqu'on veut tester la présence d'une cible pour un système IR, on teste la présence d'un élément (un pixel pour le système IR), cet élément et les éléments adjacents affectés par la cible ne devraient pas intervenir dans l'estimation de la matrice de covariance R . Ensuite, On peut tester la présence de la cible par l'ensemble de données atténuées z , en utilisant la forme du signal attendu s et les méthodes de filtrage adapté (matched filtering) discutées précédemment. Cependant, la matrice de covariance estimée \hat{R} doit être utilisée pour tester la présence de la cible dans un ensemble de N pixels. \hat{R} est calculée à partir d'un ensemble de N pixels non inclus dans l'ensemble cible probablement testé.

En utilisant le principe illustré dans la Figure (1-8), les éléments du vecteur y de dimension $N \times 1$ sont définis par

$$y_n = s_n^T \hat{R}^{-1} z \quad (1.19)$$

Où s_n est le vecteur du signal attendu étant donné qu'une cible est présente dans le pixel n . Ces éléments statistiques y_n sont utilisés pour tester la présence de la cible dans le pixel n . Le fait qu'une covariance estimée \hat{R} , plutôt que la matrice de covariance réelle, est utilisée conduit à une distribution de fausse d'alarme qui a un comportement plus large que la distribution gaussienne qui résulterait si la vraie covariance était connue. Cette distribution est discutée dans [59].

1.3.2.3 Détection séquentielle

L'approche de la détection séquentielle utilise l'information du signal initial pour trois affectations de ressources de calcul des capteurs. Cette approche est plus directement applicable

à la répartition de l'énergie radar à faisceau agile où, comme l'explique Billam [56]. En utilisant la méthode de confirmation d'alerte, une détection d'alerte de seuil inférieur pendant la recherche déclenche l'application des ressources radar sous la forme d'un temps d'attente de confirmation de TOT (Time On Target) plus long. Ensuite, un dépassement de seuil sur l'étape de confirmation est également nécessaire pour déclarer la présence de la cible. Cantrell [60] discute une problématique similaire pour un radar à balayage avec la possibilité de faire varier la densité de puissance spatiale transmise.

Bien que les capteurs IR n'aient pas la flexibilité de direction du faisceau du radar, l'approche de détection séquentielle peut être appliquée à la répartition des ressources de calcul pour un système IR. Blostein et al [61][62] et Stocker et Jensen [63] utilisent le SPRT tronqué pour implémenter plus efficacement l'approche AVF. Cette méthode permet d'identifier rapidement les trajectoires à faible et haute vraisemblance afin que les ressources informatiques puissent être appliquées aux trajectoires probables des cibles à faible RSB.

1.4 Extraction et seuillage

L'étape de détection et d'extraction vise à détecter les cibles potentielles et à extraire leurs paramètres des données radar brutes z_k . Ce processus est effectué en deux étapes. Premièrement, l'étape de détection qui fournit des pics "hits" de détection. Deuxièmement, l'étape d'extraction qui regroupe les pics "hits" de détection et extrait les paramètres des cibles.

Dans ce mémoire de thèse, nous considérerons deux cas simples où les mesures images et les mesures radar ne sont composées que de signaux cibles et de bruit additif homogène avec une variance connue. Le cas réel d'un bruit additif non-homogène ou un fouillis (clutter) ne sera pas considéré dans les applications traitées. En raison de cette limitation, la première étape de détection consiste simplement à comparer chaque échantillon $|z_k^l|^2, l = 1, \dots, N$ (où N est le nombre de cellules et z_k^l le signal dans la cellule) avec un seuil γ , donc la procédure de détection définie dans l'équation (1-19).

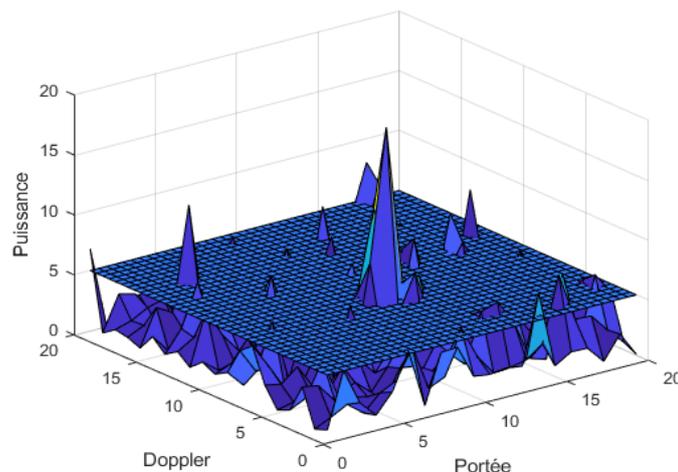


Figure 1-9 Procédure de détection pour la mesure radar en portée et en azimut.

Comme le bruit considéré est gaussien circulaire avec la variance σ^2 , le seuil γ est donné par l'expression suivante :

$$\gamma = -2\sigma^2 \ln(P_{fa}) \quad (1.20)$$

La probabilité de détection de la cible P_D dépend du rapport signal sur bruit (RSB) de la cible et la procédure de détection est illustrée dans la Figure (1-9). Bien entendu, en présence d'un bruit de variance inconnue, cette procédure de détection simple serait remplacée par une procédure adaptative, par exemple un détecteur classique de taux constant de fausses alarmes (CFAR).

Ensuite, une procédure simple pour extraire le paramètre serait de considérer comme estimation de paramètre la valeur correspondante (par exemple $(r^l, \dot{r}^l, \theta^l)$) pour toute cellule qui dépasse le seuil. Toutefois, dans la pratique, d'autres développements sont nécessaires ; en effet, si le rapport RSB de la cible est élevé, en raison de la fonction d'ambiguïté des lobes latéraux, une seule cible peut produire plusieurs "résultats positifs" de détection contigus.

Ainsi, une étape de regroupement est généralement ajoutée afin d'agréger les "hits" de détection susceptibles d'être générés par la même cible. Cette étape d'agrégation est souvent basée sur une procédure heuristique. Ensuite, une procédure d'estimation est appliquée à chaque résultat extrait afin de récupérer la valeur du paramètre correspondant (par exemple, portée, Doppler, azimut...). Enfin, à la fin de la phase de détection et d'extraction des "hits", un ensemble de "hits" de détection est fourni :

$$Y_k = \{y_{k,1}, \dots, y_{k,N_D}\}$$

où chaque "hit" $y_{k,1}$ est éventuellement lié à un état cible x_k par l'équation suivante :

$$y_{k,l} = H(x_k) + w_k$$

avec H une fonction connue (éventuellement linéaire) et w_k un bruit gaussien avec matrice de covariance R_k . Enfin, l'ensemble y_k est fourni à l'étape de suivi afin de former des pistes et d'améliorer l'estimation des paramètres cibles.

1.5 Algorithmes de poursuite de cibles classiques

1.5.1 Objectifs de la poursuite de cibles

La technique de poursuite de cibles consiste à estimer les paramètres d'état des cibles à travers le temps. Cette méthode se base essentiellement sur des techniques de filtrage très avancées dans le cadre Bayésien [16]. Le filtrage est une description mathématique des opérations de traitement que subit un signal mélangé au bruit. Son principe est de déterminer des estimateurs de variables du système lorsque l'environnement présente des perturbations aléatoires. Il consiste à estimer de façon récursive un état caché au vu d'observations.

Le but de la phase du filtrage est de trouver la solution efficace qui tienne compte de tous les problèmes pouvant être rencontrés dans la pratique et parmi ces problèmes ceux qui sont liés à l'environnement de poursuite comme :

- Fouillis élevé,
- La présence de fausses alarmes,

- La multiplicité des objets,
- Les cibles manouvrantes,
- Les apparitions, les disparitions et les disparitions aléatoires d'objets,
- Les trajectoires conflictuelles et autres.

Plus les problèmes de l'environnement de poursuite, il existe d'autres problèmes liés aux imperfections des instruments de mesure, notamment :

- les erreurs de mesure,
- l'occultation d'objets par rapport au positionnement des capteurs,
- les confusions entre les cibles suivies, et d'autres complexités.

Différentes suppositions sont en général adoptées pour la résolution du problème de suivi, en l'occurrence, la connaissance approximative des modèles d'évolution des objets, avec parfois les lois statistiques des variables d'état des objets. Les algorithmes de poursuite les plus utilisés dans le domaine sont présentés et discutés dans les paragraphes suivants.

1.5.2 Algorithmes de poursuite mono-cible classique

La technique de poursuite de cibles radar consiste à utiliser le radar pour observer et estimer les paramètres de la cible telle que la position, la vitesse, ...etc. et établir le modèle dynamique correspondant au mouvement de la cible. Ensuite, la prédiction et l'évaluation de l'état suivant de la cible grâce à une série de méthodes de filtrage pour estimer avec précision la trajectoire de la cible. Les différents algorithmes utilisés pour la poursuite mono-cible sont présentés par la figure (1-10). En général, l'algorithme de poursuite mono-cible se base sur deux parties : la première est l'estimation d'états, la deuxième est le changement de modèle d'état d'une cible mobile.

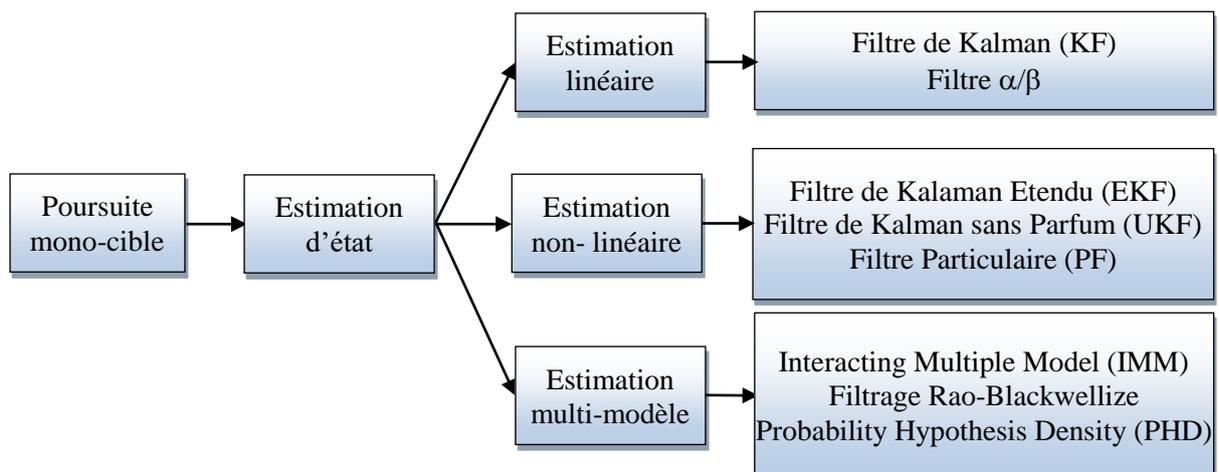


Figure 1-10 Schéma descriptif des algorithmes classiques de poursuite mono-cible

On commence par l'estimation d'état, il existe l'algorithme d'estimation d'état linéaire et l'algorithme d'estimation d'état non linéaire. Au début du XIXe siècle, le mathématicien Gauss

a proposé la méthode des moindres carrés, qui a été appliquée pour observer l'orbite de la planète. Ensuite, dans les années 1940, avec la croissance des besoins du système radar, Wiener a conçu et proposé le filtre Wiener [64]. La méthode a utilisé l'équation de Wiener-Hopf pour résoudre la solution analytique de la fonction de transfert optimale afin d'obtenir le déclenchement et la suppression du signal. Ensuite, un filtre α/β a été proposé pour l'analyse du système de suivi du bord (edge tracking system). En tant que filtre à gain constant, il a été largement utilisé pour les avantages d'un petit calcul et d'une implémentation facile. Dans les années 1960, avec l'amélioration continue et le développement de la théorie de l'estimation optimale, le chercheur américain Kalman a dérivé le filtre de Kalman [1]. L'algorithme introduit le concept d'espace d'état, utilise l'espace d'état pour exprimer la relation entre l'entrée et la sortie, et estime l'information requise à partir des données mesurées. Le filtre de Kalman est limité aux systèmes linéaires. Dans la pratique, la manœuvre de la cible est généralement non linéaire donc on passe à l'estimation non-linéaire. A cet égard, les chercheurs ont étudié le filtrage non linéaire basé sur le filtre de Kalman. Il existe quatre méthodes principales : (1) algorithme amélioré basé sur le développement de Taylor du premier ordre pour linéariser le problème non linéaire en se basant sur KF et a proposé le filtre de Kalman étendu (EKF). EKF présente les avantages d'une structure simple, d'une grande facilité d'utilisation. Toutefois, en raison de l'erreur de linéarisation dans le processus de EKF, l'effet est faible ou même divergent lorsque le degré de non-linéarité est élevé. Afin de résoudre le problème des énormes erreurs dans la forte non-linéarité de l'EKF, les chercheurs l'ont amélioré et mis de nombreux nouveaux algorithmes. (2) algorithme amélioré basé sur un échantillonnage déterministe, Julier a d'abord proposé l'algorithme du filtre de Kalman sans parfum (UKF) [65]. L'algorithme utilise la fonction de densité de probabilité pour approximer la fonction non linéaire en sélectionnant $2n + 1$ points sigma, et la précision de l'évaluation peut atteindre le second ordre. Afin de résoudre le problème de l'échantillonnage non local et de la matrice croisée d'ordre élevé, Julier propose une méthode pour réduire le nombre de points d'échantillonnage en 2002[66]. (4) algorithme amélioré basé sur l'échantillonnage aléatoire : Tous les algorithmes ci-dessus ne peuvent traiter que les caractéristiques statistiques du bruit du système non linéaire gaussien. Pour le bruit non gaussien, il est nécessaire de mettre en œuvre le filtre à particules (FP), qui est basé sur la méthode de Monte Carlo et l'estimation bayésienne. Dans les années 1950, le scientifique américain Hammersley a proposé de façon créative l'algorithme d'échantillonnage séquentiel important (SIS)[67]. Cet algorithme a été utilisé pour traiter l'estimation d'état en physique et en statistique, ce qui a jeté les bases théoriques de la génération des PF. Dans les années 1970, de nombreux experts ont étudié le SIS afin qu'il soit développé. Les experts ont également trouvé un problème, à savoir la dégénérescence des particules. La dégénérescence des particules entraîne le gaspillage des ressources informatiques et la déviation directe des résultats. Le problème n'a pas été bien réglé jusqu'à ce que Gordon introduise l'algorithme de ré-échantillonnage dans le bootstrap [68] en 1993, dans une certaine mesure, pour résoudre le problème de la dégradation des particules, mais le calcul a été amélioré.

Deuxièmement, la classe de changement de mouvement de l'état de la cible. Par conséquent, il est important d'établir le modèle mathématique pour avoir de bonnes performances du

processus de suivi des cibles. Le modèle de mouvement de la cible de manœuvre est divisé en modèle simple et modèle multiple en fonction du nombre de modèles.

En 1973, Bridgewater et Friedland ont successivement proposé le modèle de vitesse constante (CV) et le Modèle d'accélération constante (CA). En 1992, Waston et Blair a établi le modèle de virage coordonné (TC).

Algorithme multi-modèles de première génération. En 1965, Magill a proposé la première génération de l'algorithme multi-modèle, qui était basé sur différents modèles de filtres fonctionnant en parallèle et ensuite la fusion des sorties. Algorithme multi-modèles de deuxième génération où le nombre de modèles est toujours fixe, mais le modèle sélectionné a une interaction. Il existe principalement des algorithmes GPB et IMM. (1) Algorithme GPB En 1970, Ackerson a proposé l'algorithme généralisé de Pseudo-Baysien (GPB). L'algorithme considère que chacun des modèles sélectionnés est conforme à l'état de mouvement de la cible et effectue la même entrée pour chaque modèle. Toutefois, l'algorithme ne tient pas compte des caractéristiques de chaque modèle. Il utilise l'information du modèle, par conséquent il ne peut pas être appliqué à grande échelle. (2) Algorithme IMM : En 1988, Blom et Bar-Shalom ont proposé un nouvel algorithme pour approximer l'état du mouvement de la cible en pondération probabiliste de plusieurs modèles basés sur l'algorithme GPB, à savoir l'Interacting Algorithme des modèles multiples [69] (IMM), traite la transition entre les modèles comme un processus de Markov et les transforme au moyen d'un algorithme matrice de transfert probabiliste. L'algorithme a été largement utilisé en raison de ses avantages tels que l'absence de besoin de détection de manœuvres, structure simple, calcul modéré, etc.

1.5.3 Algorithmes de poursuite multi-cibles classiques

La poursuite radar multi-cibles (MTT) [70] est parmi les problèmes de poursuite les plus difficiles. Les premières solutions proposées utilisaient l'analyse séquentielle afin d'initialiser ou de supprimer une piste. Les pistes ont été associées via la règle de l'association des plus proches voisins qui consiste à fixer des résultats de détection aux pistes existantes d'une manière qui minimise un certain critère de distance. Cependant, cette approche peut conduire à des mauvaises associations, surtout lorsqu'il y a un taux de fausses alarmes élevé, et, par conséquent, à des mauvaises performances de poursuite. Ensuite, de nouveaux algorithmes ont été proposés dans un cadre bayésien qui sont capables de traiter de telles situations. La première a été proposée par Singer et al [71] et est désignée comme Multiple Hypothesis Tracking (MHT). Il s'agit d'un algorithme orienté (c'est-à-dire que les hypothèses sont calculées à partir des mesures) où l'idée clé est de considérer toutes les hypothèses possibles afin d'initialiser, maintenir ou supprimer des pistes, c'est-à-dire à un instant donné k , tout pic (hit) considéré peut-être affecté à une piste existante, ou initialiser une nouvelle piste, ou être associé à une fausse alarme. La solution serait alors apportée par l'hypothèse la plus probable. Cette approche conduit à un certain nombre d'hypothèses qui se dissipent extrêmement rapidement avec le temps, de sorte que cette approche conduit à une complexité qui peut être difficile à gérer dans un délai raisonnable. Une approximation sous-optimale a donc été proposée par Reid [26] en 1979 qui permet de rendre possible la VMH par l'élagage d'hypothèses à faibles probabilités.

En 1975, Bar-Shalom et ses collaborateurs [21] ont proposé une autre approche, connue sous le nom de Probabilistic Data Association Filter (PDAF). Contrairement au MHT qui gère l'ensemble de la problématique MTT (c'est-à-dire le suivi des étapes de vie et le problème d'association), le PDAF est consacré uniquement au problème de l'association. Par conséquent, il suppose le nombre de cibles connues (il s'agit d'un algorithme poursuite de cible orienté) et ne fournit ni l'initialisation ni la terminaison de piste. Notez que le PDAF peut échouer lorsque plusieurs pistes sont fermées car il ne prend pas en compte l'interaction possible entre elles. Pour faire face à cette situation, il a ensuite été proposé de créer le Joint PDAF (JPDAF)[28]. Pour de tels filtres, l'initialisation et la terminaison de la piste se fait souvent en utilisant la règle "M sur N" qui consiste à initialiser une piste si une détection est présente dans la porte de validation [72] d'une piste d'initialisation donnée au moins M fois sur N itérations [73] [74]. Une règle similaire s'applique pour la terminaison de la piste. Les solutions MHT et PDAF effectuent le suivi lui-même pour une association piste/pic (track/hit) donnée grâce à un filtre bayésien, généralement le célèbre filtre de Kalman.

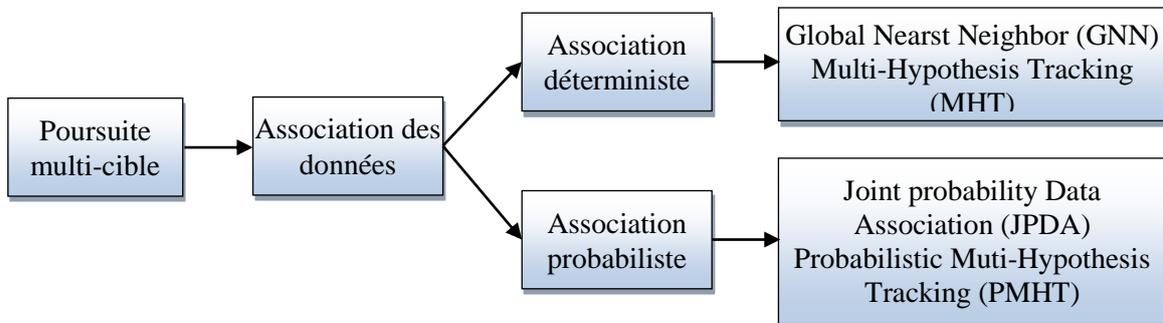


Figure 1-11 Schéma descriptif des algorithmes classiques de poursuite multi-cibles

1.6 L'approche Track Before Detect

L'objectif fondamental de l'approche TBD est de retarder le processus de seuil de détection le plus longtemps possible afin d'intégrer l'intensité de la cible sur plusieurs regards. C'est la même philosophie sous-jacente qui est employée dans les méthodes de détection avancées, comme l'AVF (assumed velocity matched filter). La principale distinction est que les approches de détection discutées précédemment sont généralement basées sur un temps continu sur la cible, tandis que le TBD peut fonctionner sur des données cibles d'entrée discontinues. Comme les méthodes TBD utilisent plusieurs balayages de données, une estimation de l'état cible, incluant généralement la vitesse et la position, est obtenue au cours du processus de détection. Enfin, certaines méthodes TBD, comme l'algorithme de programmation dynamique [75][76], pénalisent, mais n'interdisent pas, les écarts par rapport à la ligne droite.

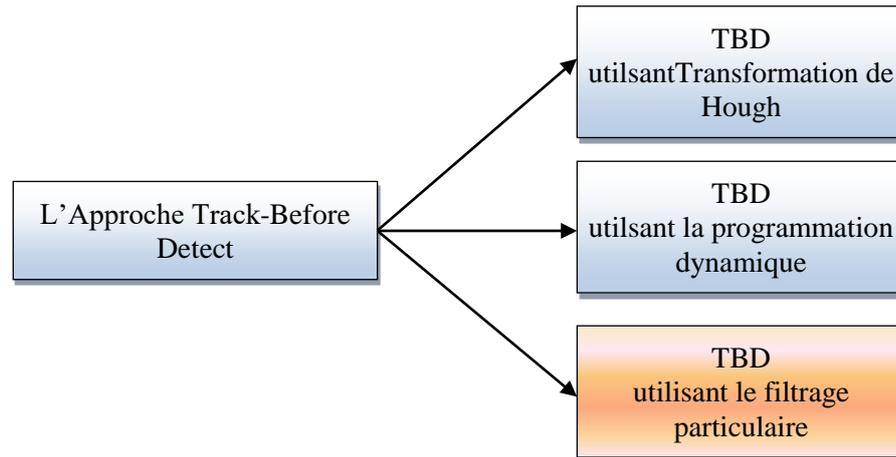


Figure 1-12 Schéma descriptif des différentes approches TBD

La présente section propose trois applications de l'approche à déterminer. La première application, la transformation de Hough, est une méthode TBD dans laquelle les données mesurées sont transformées en bacs stationnaires dans l'espace d'état cible. Dans ce cas, les bacs représentent les deux paramètres normaux d'une ligne droite [77] [78]. Bien que des extensions à d'autres types de courbes aient été faites, la transformation de Hough s'applique surtout aux cibles linéaires. La deuxième application est l'APD dans laquelle la cible se déplace à travers différents conteneurs spatiaux d'état avec le temps [75][76]. L'approche DPA est plus souple et plus facilement applicable aux cibles de manœuvre, mais elle est aussi plus exigeante sur le plan du calcul.

Des exemples relativement simples sont choisis à des fins d'illustration. Après [79], la transformée de Hough est appliquée à la cible entrante radiale, de sorte que les paramètres de suivi sont la portée en fonction du temps. Une application plus complexe, discutée dans [77][80], se dirige vers des cibles en ligne droite dans l'espace de position. Suivre [75][81], l'application de la APD à l'espace 4D (deux angles et deux taux d'angle) est discutée. Cependant, un exemple de radar plus simple, similaire à [76]. L'utilisation d'une plage d'état unique, le taux de plage, est utilisé pour l'illustration. Enfin, une méthode non cellulaire à base de TBD est abordée dans cette section et une comparaison de performance entre cette méthode et la méthode MHT.

1.6.1 TBD utilisant la transformation de Hough

Pour la transformation de Hough, les données mesurées sont transformées en cellules stationnaires dans l'espace d'état de la cible. En général, les cellules représentent les deux paramètres normaux d'une ligne droite. La référence [16] utilise un exemple d'une cible à faible intensité radiale entrante avec une vitesse radiale presque constante. Dans ce cas, la ligne droite à détecter définit la portée de la cible en fonction du temps présenté par l'équation suivante :

$$\rho = R \cos \theta + t \sin \theta \quad (1.21)$$

ρ et θ sont décomposés en cellules qui se répartissent sur la portée et les angles qui sont les suivants à l'étude. Compte tenu d'une portée mesurée à un moment et à un angle donné,

l'équation (1.21) est utilisée pour calculer ρ et cette mesure est placée dans la case appropriée (ρ, θ) .

Une limitation de la transformée de Hough est que, tout comme le filtre de vitesse, il suppose que la cible se déplace en ligne droite. Les cibles qui s'écartent de cette hypothèse ne seront pas aussi facilement détectées. Cependant, les méthodes de transformation de Hough sont moins intensives en calcul que d'autres techniques telles que celle de la programmation dynamique.

1.6.2 TBD utilisant la programmation dynamique

Comme pour la transformation de Hough, l'algorithme de programmation dynamique (APD) divise l'espace d'état cible en cases (bins). Pour les applications IR, les états cibles typiques sont les angles d'azimut et d'élévation et leur vitesse angulaire correspondante. Le APD implémente l'algorithme de Viterbi [16] et associe un score pour chaque case. Le score est calculé à l'aide de l'équation suivante :

$$score = \sum \left\{ \begin{array}{l} \text{Log - likelihood} \\ \text{of Amplitude} \end{array} + \begin{array}{l} \text{Log - transition} \\ \text{probability} \end{array} + \begin{array}{l} \text{Log - prior} \\ \text{probability} \\ \text{of state} \end{array} \right\} \quad (1.22)$$

Où, i et j sont les numéros de case et k est l'index d'un scan particulier.

La différence importante entre la méthode APD et les autres méthodes TBD est l'inclusion de la méthode APD. Les deuxième et troisième termes de (1.22), qui permettent à la DPA de détecter les cibles manouvrantes. Les transitions d'une case à l'autre sont pondérées en fonction de la probabilité que la cible réalise l'accélération requise. La fonction de score est utilisée pour déterminer la transition la plus probable entre les scans pour chaque case. Cette transition est enregistrée pour chaque emplacement. Après N balayages, le score de chaque case est comparé à un seuil et si le score dépasse le seuil, une cible est déclarée, dont la trajectoire est la suivante déterminée par les transitions stockées entre les cases. L'algorithme de viterbi suppose que la cible suit un mouvement de Markov du premier ordre. Sachant que, le mouvement de la cible du balayage $k - 1$ au balayage k est indépendant du balayage précédent. L'inconvénient de l'APD est sa complexité et le fait qu'elle nécessite beaucoup de temps de calcul. Cela limite l'utilisation de l'APD dans un contexte temps réel ou quasi temps réel. L'avantage évident de l'APD est sa capacité à détecter les cibles de manouvrante. Avec l'avènement de processeurs plus rapides et moins chers, les techniques de APD deviennent de plus en plus réalisables et courantes.

1.6.3 TBD utilisant le filtrage particulière (Noncellular TBD)

La transformée de Hough et la méthode APD présentée précédemment, ainsi que la plupart des autres méthodes TBD proposées, divisent directement l'espace d'état cible en cellules de surface finie (volume). Ensuite, les données sous forme d'amplitude ou de vraisemblance du signal accumulé sont projetées dans ces cellules. L'hypothèse inhérente à cette approche est que la cible (si elle est présente) est toujours au centre de l'une de ces cellules. Cependant, le mouvement réel de la cible est continu dans l'espace d'état. Il existe, en réalité, un bruit fictif de

manœuvre de cible (processus) introduit par la restriction artificielle voulant que la cible soit modélisée comme si elle était contrainte d'être seulement au centre de la case (bin).

Les effets de la granularité cellulaire peuvent être réduits par l'utilisation de petites cellules, mais cela conduit des calculs énormes. De plus, il y aura une perte dans le score accumulé à mesure que les probabilités de transition, telles que P_{ij} , sont réduites pour tenir compte du plus grand nombre de transitions probables. Ainsi, une autre méthode non cellulaire bayésienne est basé sur le TBD a été développée et est décrite dans [82].

Plutôt que de répartir l'espace d'état cible dans les cases, la méthode décrite dans [82] maintient une représentation continue sur le champ de la LLR (log-likelihood ratio) associée à la présence de la cible dans tout l'espace d'état cible. Les probabilités (et les LLR résultants) sont propagées (à l'aide de l'intégration de Monte Carlo) conformément à un modèle cible de Markov et mises à jour avec les LLR mesurées au fur et à mesure que de nouvelles données sont reçues. La représentation finie du champ nécessaire à l'implémentation informatique est obtenue en échantillonnant le champ LLR continu avec une finesse suffisante pour que l'ensemble du champ puisse être reconstruit n'importe où dans le champ grâce à des procédures d'interpolation appropriées. Toutefois, dans sa forme actuelle, cette méthode part du principe qu'il n'y a tout au plus qu'une seule cible présente sur le champ.

La méthode TBD non cellulaire utilise l'échantillonnage et l'interpolation du champ LLR. Le modèle utilisé, le processus de Markov et la mesure log-likelihood sont représenté avec précision, évitant ainsi les pertes inhérentes aux approches cellulaires à base de TBD.

1.7 Conclusion

Dans ce premier chapitre nous avons traité la théorie de la détection et la poursuite de cible classique utilisée dans le cas de cibles avec un rapport signal sur bruit élevé. Ensuite nous avons entamé la problématique de détection et poursuite de cibles à faible rapport signal sur bruit dit cibles furtives qui constitue l'un des objectifs du travail réalisé dans le cadre de cette thèse. Nous avons commencé par les méthodes classiques telles que la détection TFAC ensuite les différentes techniques de traitement du signal pour la détection des cibles furtives. Ensuite nous avons entamé la problématique de poursuite de cibles en donnant quelque exemple d'algorithmes de poursuite de mono-cible et le cas multi-cibles. Enfin, on a introduit la méthode track before-detect utilisée pour la détection et la poursuite de cibles furtives et on a donné des détails de différentes méthodes TBD classiques utilisées dans la littérature ouverte.

2. LE FILTRAGE BAYESIEN

2. LE FILTRAGE BAYESIEN	40
2.1 Introduction	41
2.2 Processus markovien et modèle d'état	41
2.3 Equation du filtrage non-linéaire	43
2.4 Algorithmes Bayésiens récurrents exacts (optimaux)	45
2.4.1 Modèle de Markov caché (HMM).....	45
2.4.2 Filtre de Kalman (KF)	45
2.5 Algorithmes Bayésiens récurrents sous-optimaux	47
2.5.1 Filtre de Kalman étendu (EKF)	47
2.5.2 Filtre de Kalman sans parfum (UKF)	48
2.5.3 Filtrage particulaire	50
2.6 Estimation multi-modèles	50
2.7 Modélisation des trajectoires de la cible	51
2.7.1 Les modèles non-manouvriers	52
2.7.1.1 Modèle à vitesse constante (CV).....	52
2.7.2 Les modèles manouvriers avec les coordonnées-découplées.....	53
2.7.2.1 Modèle à accélération constante (CA) (Wiener-Process Acceleration Model)	54
2.7.3 Les modèles manouvriers du mouvement horizontal à 2-D.....	55
2.7.3.1 Modèle de virage (CT) avec taux de rotation connu	56
2.8 Conclusion.....	57

Ce chapitre est consacré à la présentation des différentes méthodes d'estimation d'état les plus utilisées dans le domaine de poursuite de cibles.

2.1 Introduction

L'un des problèmes les plus compliqués en traitement du signal et en automatique est l'estimation d'un signal utile $x(t)$ appelé l'état (l'espace d'état) à partir de l'observation d'un autre signal $z(t)$, avec lequel le signal $x(t)$ est corrélé. Dans les applications radars et d'autres applications, le signal $z(t)$ est considéré comme une version bruitée de $x(t)$, mais il y a des cas où il peut se considérer comme un signal différent qui contient de l'information sur l'état $x(t)$. Notre objectif est d'effectuer une application radar, et dans ce cas les observations bruitées, de la portée et du décalage fréquentiel après la phase de seuillage par le filtrage adapté peuvent être utilisées en conjonction avec une observation angulaire pour l'estimation des paramètres de la cible comme la position, la vitesse radiale et l'accélération. Ce chapitre est organisé comme suit : nous commençons par la présentation du problème de filtrage dans le cas général. Ensuite, il existe plusieurs méthodes classiques pour résoudre ce genre de problème telles que les approches exactes et les approches sous-optimales. Nous présenterons les points forts et les limitations de ces méthodes.

En fin des années quarante (1949), N. Wiener a posé la problématique de filtrage d'un signal stochastique. Pour pouvoir résoudre ce problème il a proposé une nouvelle méthode basée sur la minimisation de l'erreur quadratique moyenne entre le signal utilisé et le signal estimé. La solution de filtrage de Wiener [64] est acceptable juste dans le cas où le signal $x(t)$ et le signal $z(t)$ sont considérés conjointement stationnaires.

Le filtre de Wiener est considéré comme un cas particulier du filtre de Kalman [1]. Ce dernier utilise une approche temporelle pour obtenir un système optimal au sens de la minimisation de la variance d'erreur.

L'objectif de l'estimation d'état est de trouver des estimateurs des variables d'états d'un système dynamique bruité observé partiellement. Donc, en fonction de la quantité de l'information on peut classer la problématique de l'estimation d'état. Par exemple, on veut estimer les paramètres d'état x d'un système dynamique à l'instant t à partir des données d'observation bruitées $z(t_0, t_f)$ existantes entre l'instant initial t_0 et l'instant final t_f . A chaque intervalle d'observation le problème traité porte un nom différent :

- Si $t_f = t$, donc c'est un problème de filtrage.
- Si $t_f < t$, donc c'est un problème de prédiction.
- Si $t_f > t$, donc c'est un problème de lissage.

2.2 Processus markovien et modèle d'état

C'est très important de présenter un système déterministe par un concept d'état. Cela explique qu'à un instant t l'état d'un système $x(t)$ et son équation d'état incluent toutes les informations du passé de ce système. Ces informations sont importantes pour l'étape de prédiction de la future réponse de système. En d'autres termes, l'état inclue toutes les conditions initiales du système qui sont essentielles pour le calcul de la sortie du système. On peut déterminer l'état d'un processus stochastique lorsque ce processus est Markovien. Par exemple,

on a un processus stochastique Markovien $x(t)$ pour tout $t_1 < t_2 < \dots < t_k < t$, dans ce cas la densité de probabilité conditionnelle est distinguée par la propriété suivante :

$$p(x(t)|x(t_1), x(t_2), \dots, x(t_k)) = p(x(t)|x(t_k)) \quad (2.1)$$

Ce qui signifie que même si on connaît plusieurs valeurs antérieures du processus, juste la valeur la plus récente fournit l'information sur la densité de probabilité de l'état $x(t)$. Supposant $x(t)$ une séquence aléatoire qui accepte qu'un nombre fini de valeurs possibles, alors dans ce cas c'est une chaîne de Markov. Notre problématique s'adresse aux processus de Markov non-linéaire discret $(x_k)_{k \in \mathbb{N}}$. Le modèle de l'équation d'état est donné par l'expression suivante :

$$x_k = f(x_{k-1}) + v_k \quad (2.2)$$

où $k \in \mathbb{N}$ est l'instant de temps, x_k est un processus stochastique vectoriel sachant que $x_k \in \mathbb{R}^{N_x}$, f est une fonction non-linéaire connue de $\mathbb{R}^{N_x} \rightarrow \mathbb{R}^{N_x}$ et où v_k est le processus de bruit blanc de moyenne nulle indépendant de x_k , et de matrice de covariance Q , telle que :

$$E[v_k v_j^T] = Q \delta_{kj} \quad (2.3)$$

Sachant que Q est une matrice symétrique semi-définie positive. Dans l'équation (2.2), x_k est le vecteur d'état, f est la fonction d'état et v_k est souvent appelé le bruit d'état.

Pour analyser un système dynamique ainsi que l'équation d'état du système donné par l'équation (2.2) qui exprime l'évolution de l'état dans le temps, il est nécessaire de définir un autre modèle qui relie le processus stochastique d'observation (ou de mesure) z_k au processus stochastique d'état x_k . L'équation de modèle de mesure est donnée par l'expression suivante :

$$z_k = h(x_k) + w_k \quad (2.4)$$

où $z_k \in \mathbb{R}^{N_z}$ est un processus stochastique vectoriel et $w_k \in \mathbb{R}^{N_z}$ est un vecteur de bruit blanc de moyenne nulle indépendant de z_k , non corrélé au bruit du processus avec une matrice de covariance R telle que :

$$E[w_k w_j^T] = R \delta_{kj} \quad (2.5)$$

Sachant que R est une matrice symétrique semi-définie positive. Dans l'équation (2-4), z_k est le vecteur d'observation, h est la fonction de mesure et w_k est souvent appelé le bruit de mesure. On suppose que Les mesures z_k sont conditionnellement indépendantes du processus d'état et dépend seulement de l'état courant. Un tel processus est alors appelé processus à représentation Markovienne. La caractéristique de l'indépendance conditionnelle des vecteurs de mesures et structure markovienne du processus d'état nous donne une chaîne de Markov cachée, présentée dans la figure (2-1).

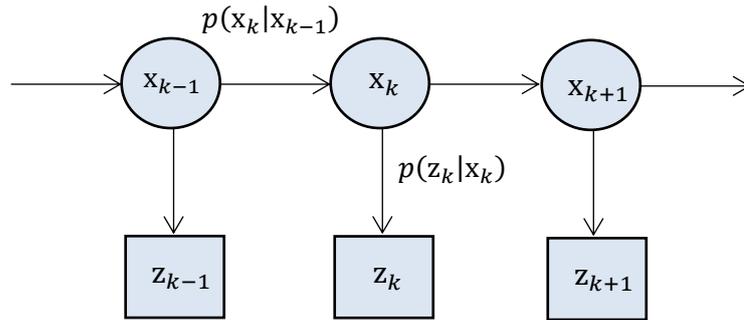


Figure 2-1 Schéma fonctionnel du modèle de Markov caché

Les deux équations (2.2) et (2.4) présentent le modèle d'état du système. Afin que ce modèle d'état décrive la densité de probabilité de l'état x_k pour tout $k \geq 0$ ainsi que la densité de probabilité de la mesure z_k pour tout $k > 0$, il est nécessaire de donner d'autres informations sur l'état initial x_0 et sur la densité de probabilité du bruit d'état v_k et la densité de probabilité du bruit de mesure w_k . Dans la plupart des applications, les densités de probabilité des bruits sont considérées gaussiennes. Dans le cas où on est limité par la connaissance des moments d'ordre 1 et 2 du processus x_k (c.à.d : la moyenne, la fonction de covariance, la densité spectrale) il suffit juste d'initialiser ces moments pour l'état initial x_0 . Ensuite on peut trouver facilement la moyenne et la fonction de covariance de la mesure z_k à partir de celles de l'état x_k . La Figure (2-2) montre une description d'un modèle d'état de dimension finie.

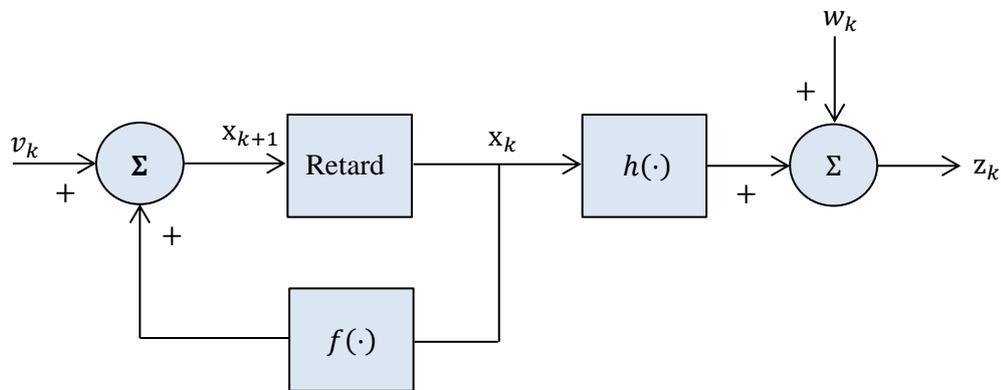


Figure 2-2 Représentation schématique du modèle d'état

2.3 Equation du filtrage non-linéaire

Le but du filtrage est de chercher les estimations de l'état x_k sur la base d'une séquence de toutes les mesures disponibles $z_{1:k} = \{z_i, i = 1, \dots, k\}$ jusqu'à l'instant k . En se basant sur l'approche bayésienne, le problème est de quantifier récursivement un degré de confiance sur l'état x_k à l'instant k , étant donné les observations $z_{1:k}$. Ensuite, il est important de construire la probabilité a posteriori $p(x_k | z_{1:k})$. Sachant que la densité de probabilité initiale du vecteur d'état est donnée par $p(x_0)$. En principe, la densité de probabilité $p(x_k | z_{1:k})$ peut s'obtenir d'une manière récursive suivant deux étapes : la prédiction et la correction.

On considère que la densité de probabilité désirée $p(x_{k-1}|z_{1:k-1})$ à l'instant $k-1$ est connue. L'étape de prédiction exige l'utilisation de l'équation du modèle d'état donnée à travers la formule des probabilités totales :

$$p(x_k|z_{1:k-1}) = \int_{x_{k-1}} p(x_k|x_{k-1}, z_{1:k-1}) p(x_{k-1}|z_{1:k-1}) dx_{k-1} \quad (2.6)$$

Si x_k est un processus Markovien du premier ordre, alors on peut écrire $p(x_k|x_{k-1}, z_{1:k-1}) = p(x_k|x_{k-1})$, et la densité de prédiction sera donnée par l'équation de Chapman-Kolmogorov suivante:

$$p(x_k|z_{1:k-1}) = \int_{x_{k-1}} p(x_k|x_{k-1}) p(x_{k-1}|z_{1:k-1}) dx_{k-1} \quad (2.7)$$

Sachant que le modèle probabiliste de l'évolution de l'état x_{k-1} à l'état x_k est appelé la densité de transition d'état donnée par $p(x_k|x_{k-1})$, est définie par l'équation d'état (2.2) et les distributions statistiques connues de v_k , soit :

$$p(x_k|x_{k-1}) = p_v(x_k - f(x_{k-1})) \quad (2.8)$$

Quand la mesure $z_{1:k-1}$ est disponible à l'instant k , on entame l'étape de la mise à jour (la correction). Cela nécessite une mise à jour de la densité de prédiction suivant la loi de Bayes conditionnellement à la mesure $z_{1:k-1}$ pour trouver la loi à posteriori à l'instant k donnée par :

$$p(x_k|z_{1:k}) = \frac{p(z_k|z_k, z_{1:k-1})p(x_k|z_{1:k-1})}{p(z_k|z_{1:k-1})} \quad (2.9)$$

L'expression (2.7) donne la prédiction récursive bayésienne et l'expression (2.9) donne le filtrage récursif bayésien. $p(z_k|x_k, z_{1:k-1})$ est nommée la vraisemblance conditionnelle. Nous remarquons que pour une mesure modélisée par l'équation (2.4), la vraisemblance conditionnelle est donnée par $p(z_k|x_k, z_{1:k-1}) = p(z_k|x_k)$, et elle est définie par les distributions statistiques connues de w_k comme suit :

$$p(z_k|x_k) = p_w(z_k - h(x_k)) \quad (2.10)$$

En outre, $p(z_k|z_{1:k-1})$ est donnée par l'expression (2.11) des probabilités totales.

$$p(z_k|z_{1:k-1}) = \int_{x_{k-1}} p(z_k|x_k, z_{1:k-1}) p(x_k|z_{1:k-1}) dx_k \quad (2.11)$$

Le filtre de Kalman donne une solution optimale lorsque les fonctions d'état et d'observation f et h sont linéaires et les densités de probabilité des bruits v et w sont gaussiennes. Dans le cas de la non-linéarité des deux équations du système, le filtre de Kalman étendu sous-optimal est utilisé pour résoudre le problème par la linéarisation de ces deux équations, tout en gardant l'hypothèse des distributions gaussiennes. Dans le cas d'un système non linéaire et non gaussien, il existe des nouvelles méthodes numériques comme le filtrage particulaire (PF) qui donne une bonne approximation de la solution exacte au problème du filtrage bayésien.

2.4 Algorithmes Bayésiens récurrents exacts (optimaux)

2.4.1 Modèle de Markov caché (HMM)

Le processus donné par l'équation de prédiction (2.7) et l'équation de mise à jour de la prédiction (2.9) n'admet pas des solutions analytiques. Par contre il existe une solution conceptuelle au problème de filtrage bayésien récurrent. Cependant, si x_k fait partie d'un espace d'état discret et fini, on obtient un modèle de Markov caché (Hidden Markov Model (HMM) en anglais). Les intégrales dans les équations (2.7) et (2.9) deviennent des sommes simples à calculer. Par exemple, si l'espace d'état nommé par Ω et de cardinal N , est donné par $\Omega = \{x_1, x_2, \dots, x_N\}$, l'équation de prédiction devient :

$$P_r(x_k = x_i | z_{1:k-1}) = \sum_{j=1}^N P_r(x_k = x_i | x_{k-1} = x_j) P_r(x_{k-1} = x_j | z_{1:k-1}) \quad (2.12)$$

pour $i = 1, 2, \dots, N$. Le terme $P_r(x_k = x_i | x_{k-1} = x_j)$ est un élément de la matrice de transition Markovienne. De la même façon, on peut écrire l'équation de correction (mise à jour) comme suit :

$$P_r(x_k = x_i | z_{1:k}) = \frac{p(z_k | x_k = x_i) p(x_k = x_i | z_{1:k-1})}{\sum_{j=1}^N p(z_k | x_k = x_j) P_r(x_k = x_j | z_{1:k-1})} \quad (2.13)$$

Comme la récursivité dans les équations (2.12) et (2.13) ne demande que la possibilité d'évaluation des probabilités de transition $P_r(x_k = x_i | x_{k-1} = x_j)$ et la fonction de vraisemblance $p(z_k | x_k = x_i)$, ce type de filtres est applicable juste pour le cas des espaces d'état discrets. Dans le cas de la problématique traitée, on ne peut pas appliquer cette hypothèse. Ainsi, la prochaine section sera consacrée à un autre algorithme récurrent bayésien exact, qui s'applique pour des espaces d'état continus.

2.4.2 Filtre de Kalman (KF)

Considérons un modèle d'état x_k linéaire, avec un bruit d'état gaussien v_k , et l'équation d'observation (de mesure) est une fonction linéaire avec un bruit de mesure gaussien w_k :

$$\begin{cases} x_k = F_k x_{k-1} + v_k \\ z_k = H_k x_k + w_k \end{cases} \quad (2.14)$$

Où

- F_k de dimension $(N_x \times N_x)$, H_k de dimension $(N_y \times N_x)$ sont respectivement la matrice de transition et la matrice de mesure.
- les bruits d'état et d'observation v_k et w_k sont des bruits blancs Gaussiens de matrices de covariance respectives Q_k et R_k . Ces bruits sont mutuellement indépendants et indépendants de la condition initiale x_0 .
- la loi initiale $p(x_0)$ est Gaussienne de moyenne $E[x_0] = x_{0|0}$ et de matrice de covariance $P_{0|0}$.

Avec les hypothèses citées avant, on montre que le couple (x, z) est gaussien et la loi a posteriori $p(x_k | z_k)$ est gaussienne. Cette dernière densité à l'instant k est représentée par :

- sa moyenne : $x_{k|k} = E[x_k | z_{1:k}]$
- sa matrice de covariance $P_{k|k} = E \left[(x_k - x_{k|k})(x_k - x_{k|k})^T \mid z_{1:k} \right]$

Ces paramètres sont calculés récursivement suivant l'étape de prédiction et l'étape de mise à jour du filtre de Kalman. Sachant que $\mathcal{N}(\mu, \Sigma)$ une distribution gaussienne de moyenne μ et de matrice de covariance Σ . De même, la densité de probabilité pour la valeur x est donnée par $\mathcal{N}(x, \mu, \Sigma)$. De plus, avec l'hypothèse gaussienne du filtre de Kalman, on peut écrire $v_k \sim \mathcal{N}(0, Q_k)$, $w_k \sim \mathcal{N}(0, R_k)$ et $x_0 \sim \mathcal{N}(x_{0|0}, P_{0|0})$. On considère que l'estimation est faite à l'instant $k-1$ donc les paramètres $x_{k-1|k-1}$ et $P_{k-1|k-1}$ sont connus et la densité de probabilité a posteriori à l'instant $k-1$ est donnée par :

$$p(x_{k-1} | z_{1:k-1}) = \mathcal{N}(x_{k-1}, x_{k-1|k-1}, P_{k-1|k-1}) \quad (2.15)$$

On peut tirer de l'équation d'état (2-14) et de la distribution gaussienne du bruit d'état v_k la densité de transition qui a une forme gaussienne et elle est donnée par :

$$p(x_k | x_{k-1}) = \mathcal{N}(x_k, F_k x_{k-1|k-1}, Q_k) \quad (2.16)$$

La prédiction récursive bayésienne représentée par l'expression (2-7) donne :

$$p(x_k | z_{1:k-1}) = \int_{x_{k-1}} \mathcal{N}(x_k, F_k x_{k-1|k-1}, Q_k) \mathcal{N}(x_{k-1}, x_{k-1|k-1}, P_{k-1|k-1}) dx_{k-1} \quad (2.17)$$

L'intégrale donnée par l'équation (2.17) peut se calculer de la manière suivante [83] :

$$p(x_k | z_{1:k-1}) \triangleq \mathcal{N}(x_k, F_k x_{k-1|k-1}, F_k P_{k-1|k-1} F_k^T + Q_k) \equiv \mathcal{N}(x_k, x_{k|k-1}, P_{k|k-1}) \quad (2.18)$$

Ainsi les équations de prédiction sont données par :

$$\begin{cases} x_{k|k-1} \equiv F_k x_{k-1|k-1} \\ P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_k \end{cases} \quad (2.19)$$

Dans la phase de correction, le calcul de l'équation (2-9) est donnée par :

$$p(x_k | z_{1:k-1}) = \frac{p(z_k | x_k) p(x_k | z_{1:k-1})}{\int_{x_k} p(z_k | x_k) p(x_k | z_{1:k-1}) dx_k} \quad (2.20)$$

A partir de l'équation de mesure (2.14) et de la distribution gaussienne du bruit v_k la vraisemblance conditionnelle s'écrit de la manière suivante :

$$p(z_k | x_k) = \mathcal{N}(z_k, H_k x_k, R_k) \quad (2.21)$$

Ensuite, la probabilité a posteriori sera donnée par :

$$p(x_k | z_{1:k-1}) = \frac{\mathcal{N}(z_k, H_k x_k, R_k) \mathcal{N}(x_k, x_{k|k-1}, P_{k|k-1})}{\int_{x_k} \mathcal{N}(z_k, H_k x_k, R_k) \mathcal{N}(x_k, x_{k|k-1}, P_{k|k-1}) dx_k} \quad (2.22)$$

$$p(x_k | z_{1:k-1}) = \frac{\mathcal{N}(z_k, z_{k|k-1}, G_k) \mathcal{N}(x_k, x_{k|k-1} + K_k (z_k - z_{k|k-1}), P_{k|k-1} - K_k H_k P_{k|k-1})}{\mathcal{N}(z_k, z_{k|k-1}, G_k)} \quad (2.23)$$

Pour finir nous avons :

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) = \mathcal{N}(\mathbf{x}_k, \mathbf{x}_{k|k-1} + K_k(\mathbf{z}_k - \mathbf{z}_{k|k-1}), P_{k|k-1} - K_k H_k P_{k|k-1}) \equiv \mathcal{N}(\mathbf{x}_k, \mathbf{x}_{k|k}, P_{k|k}) \quad (2.24)$$

Où $p(\mathbf{z}_k | \mathbf{z}_{1:k})$ est définie par sa moyenne $\mathbf{z}_{k|k-1}$ et sa matrice de covariance G_k :

$$\begin{cases} \mathbf{z}_{k|k-1} \equiv H_k \mathbf{x}_{k|k-1} \\ G_k = H_k P_{k|k-1} H_k^T + R_k \end{cases} \quad (2.25)$$

et le gain du filtre de Kalman est donné par :

$$K_k = P_{k|k-1} H_k^T G_k^{-1} \quad (2.26)$$

Ainsi les équations de mise à jour (correction) sont données par :

$$\begin{cases} \mathbf{x}_{k|k-1} \equiv \mathbf{x}_{k|k-1} + K_k(\mathbf{z}_k - \mathbf{z}_{k|k-1}) \\ G_k = H_k P_{k|k-1} H_k^T + R_k \end{cases} \quad (2.27)$$

En 1961 Rudolf Emil Kalman a proposé le filtre de Kalman [1] pour résoudre le problème de filtrage des systèmes linéaires discrets. en 1961 Kalman et Bucy ont repris le filtre de Kalman pour les systèmes continus [1]. Il est considéré comme une version moderne et probabiliste de la méthode des moindres carrés, et il est capable aussi d'optimiser le critère du maximum de vraisemblance. La majorité des problèmes de poursuite sont traités par les différentes versions du filtrage de Kalman tel que le filtrage de Kalman linéaire et le filtrage de Kalman étendu. Dans le cas où les éléments des matrices F_k et H_k dépendent des observations passées, le modèle est dit "conditionnellement gaussien". Le processus $(\mathbf{x}_k, \mathbf{z}_k)$ devient non-gaussien mais les lois conditionnelles $p(\mathbf{x}_k | \mathbf{x}_{k-1})$ et $p(\mathbf{z}_k | \mathbf{x}_k)$ restent gaussiennes et le filtre de Kalman fonctionne toujours.

2.5 Algorithmes Bayésiens récursifs sous-optimaux

2.5.1 Filtre de Kalman étendu (EKF)

Les filtres bayésiens sous-optimaux approximent la vraie densité de probabilité a posteriori à une distribution gaussienne. Le filtre le plus connu dans cette classe est le filtre de Kalman étendu (Extended Kalman Filter (EKF) en anglais). Le filtre de Kalman étendu linéarise la fonction dynamique de système et de mesure utilisant le développement en série de Taylor du premier ordre. Pour cette raison l'EKF est considéré comme un filtre non-linéaire du premier ordre en conservant l'hypothèse gaussienne. La résolution de ce problème a besoin de la linéarisation de l'équation d'état autour de $\mathbf{x}_{k-1|k-1}$ de la manière suivante :

$$f(\mathbf{x}_{k-1}) \approx f(\mathbf{x}_{k-1|k-1}) + \tilde{F}_k(\mathbf{x}_{k-1} - \mathbf{x}_{k-1|k-1}) \quad (2.28)$$

et l'équation d'observation est linéarisée autour de $\mathbf{x}_{k|k-1}$ de la manière suivante :

$$h(\mathbf{x}_k) \approx h(\mathbf{x}_{k|k-1}) + \tilde{H}_k(\mathbf{x}_k - \mathbf{x}_{k|k-1}) \quad (2.29)$$

où \tilde{F}_k et \tilde{H}_k sont les matrices jacobiennes,

$$\tilde{F}_k = \left. \frac{\partial f(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}_k = \mathbf{x}_{k-1|k-1}} \quad (2.30)$$

$$\tilde{H}_k = \frac{\partial h(x)}{\partial x} | x_k = x_{k|k-1} \quad (2.31)$$

Les équations de prédiction de l'estimation d'état $x_{k|k-1}$ et de sa matrice de covariance $P_{k|k-1}$, à l'instant k , deviennent :

$$\begin{cases} x_{k|k-1} = f(x_{k-1|k-1}) \\ P_{k|k-1} = \tilde{F}_k P_{k-1|k-1} \tilde{F}_k^T + Q_k \end{cases} \quad (2.32)$$

Les équations de correction deviennent :

$$\begin{cases} x_{k|k} = x_{k|k-1} + K_k (z_k - h(x_{k|k-1})) \\ P_{k|k} = P_{k|k-1} - K_k \tilde{H}_k P_{k|k-1} \end{cases} \quad (2.33)$$

où le gain de Kalman est donné par :

$$K_k = P_{k|k-1} \tilde{H}_k^T G_k^{-1} \quad (2.34)$$

la matrice de covariance de l'innovation est donnée par :

$$G_k = \tilde{H}_k P_{k|k-1} \tilde{H}_k^T + R_k \quad (2.35)$$

Pour un filtre de Kalman linéaire, on note que les matrices de covariance $(P_{k|k})_{k \geq 0}$, $(P_{k|k})_{k-1 \geq 0}$ et le gain $(K_k)_{k \geq 0}$ ne dépendent pas des mesures $(z_k)_{k \geq 0}$. Dans ce cas on peut les pré-calculer afin d'abaisser le temps de calculs à effectuer en temps réel. En revanche, dans le cas d'un filtre de Kalman étendu, on ne peut pas calculer les matrices de covariance et de gain hors ligne car \tilde{H}_k et \tilde{F}_k sont en fonction de l'état courant et de l'état prédit estimé.

2.5.2 Filtre de Kalman sans parfum (UKF)

Le filtrage bayésien a montré que l'approximation d'une densité de probabilité est plus simple qu'approximer une fonction non-linéaire d'une forme arbitraire. Une nouvelle méthode est proposée pour remplacer la méthode de linéarisation utilisée par l'EKF. Donc une nouvelle transformation UT (Unscented Transform en anglais) est proposée pour remplacer la méthode de linéarisation des fonction f et h . la transformation UT génère un ensemble de points d'une façon déterministe dont la moyenne et la covariance sont égales à $x_{k-1|k-1}$ et $P_{k-1|k-1}$, respectivement. Ensuite, les fonctions non-linéaires sont appliquées à chacun de ces points, les points obtenus sont utilisés pour calculer la moyenne et la matrice de covariance prédite. Le filtre récursif utilisant la méthode de la transformation UT est introduit par Julier et Uhlmann [65][66] et ils l'ont nommé Filtre de Kalman sans parfum (Unscented Kalman Filter (UKF) en anglais). Considérant la densité de probabilité a posteriori à l'instant $k-1$ qui suit une loi gaussienne $p(x_{k-1}|z_{k-1}) = \mathcal{N}(x_{k-1}, x_{k-1|k-1}, P_{k-1|k-1})$, donc on peut la présenter par un ensemble de $(2N_x + 1)$ points x_{k-1}^i et leurs poids $\omega_{k-1}^i, i = 0, \dots, 2N_x$ où N_x est la dimension de l'espace d'état. Ces points sont choisis selon la transformation UT de la manière suivante :

$$\begin{cases} x_{k-1}^0 = x_{k-1/k-1} & \omega_{k-1}^0 = \frac{\kappa}{N_x + \kappa} \quad i = 0 \\ x_{k-1}^i = x_{k-1/k-1} + \left(\sqrt{(N_x + \kappa)P_{k-1/k-1}}\right)_i & \omega_{k-1}^i = \frac{1}{2(N_x + \kappa)} \quad i = 1, \dots, N_x \\ x_{k-1}^i = x_{k-1/k-1} - \left(\sqrt{(N_x + \kappa)P_{k-1/k-1}}\right)_i & \omega_{k-1}^i = \frac{1}{2(N_x + \kappa)} \quad i = N_x + 1, \dots, 2N_x \end{cases} \quad (2.36)$$

où κ est un facteur d'échelle donné par $\kappa + N_x \neq 0$, et $\sqrt{(N_x + \kappa)P_{k-1/k-1}}$ est la $i^{\text{ième}}$ ligne de la matrice L racine carrée de $(N_x + \kappa)P_{k-1/k-1}$, telle que $(N_x + \kappa)P_{k-1/k-1} = L^T L$. Ces sigma-points se propagent grâce à la vraie équation dynamique non-linéaire du système,

$$x_{k/k-1}^i = f(x_{k-1}^i) \quad (2.37)$$

Supposant que la loi prédite est une distribution gaussienne donnée par l'ensemble pondéré de points $\{x_{k/k-1}^i\}$, avec une moyenne de $x_{k/k-1}$ et comme matrice de covariance $P_{k/k-1}$

$$x_{k/k-1} = \sum_{i=0}^{2N_x} \omega_{k-1}^i \cdot x_{k/k-1}^i \quad (2.38)$$

$$P_{k/k-1} = Q_k + \sum_{i=0}^{2N_x} \omega_{k-1}^i \cdot (x_{k/k-1}^i - x_{k/k-1})(x_{k/k-1}^i - x_{k/k-1})^T \quad (2.39)$$

D'autre part, les points $x_{k/k-1}^i$ se propagent suivant l'équation de mesure réelle non-linéaire. Ainsi, l'observation prédite est présentée par :

$$z_{k/k-1} = \sum_{i=0}^{2N_x} \omega_{k-1}^i \cdot h(x_{k/k-1}^i) \quad (2.40)$$

La matrice de covariance de l'innovation est donnée par :

$$G_k = R_k + \sum_{i=0}^{2N_x} \omega_{k-1}^i (h(x_{k/k-1}^i) - z_{k/k-1})(h(x_{k/k-1}^i) - z_{k/k-1})^T \quad (2.41)$$

La moyenne et la variance de la mise à jour sont données par les équations suivantes :

$$x_{k/k} = x_{k/k-1} + K_k(z_k - z_{k/k-1}) \quad (2.42)$$

$$P_{k/k} = P_{k/k-1} + K_k G_k K_k^T \quad (2.43)$$

où le gain de Kalman est calculé par :

$$K_k = P_{xz} G_k^{-1} \quad (2.44)$$

et la matrice de covariance P_{xz} est donnée par :

$$P_{xz} = \sum_{i=0}^{2N_x} \omega_{k-1}^i (x_{k/k-1}^i - x_{k/k-1})(h(x_{k/k-1}^i) - z_{k/k-1})^T \quad (2.45)$$

Le filtre de Kalman sans parfum (UK) est plus avantageux que le filtre de Kalman étendu (EKF) en deux points. Premièrement, l'estimation de la moyenne et de la covariance reste correcte au seconde ordre, par contre, l'EKF est limité au premier ordre. Deuxièmement, l'UKF n'utilise pas de matrices jacobiniennes \tilde{F}_k ou \tilde{H}_k , ce qui évite les problèmes de calcul des dérivées partielles.

2.5.3 Filtrage particulière

Le filtre de Kalman est l'un des outils les plus puissants du traitement statistique du signal, en particulier pour l'estimation, la prédiction et le filtrage. Cependant, sa mise en œuvre n'est possible que sur des modèles d'état linéaires et gaussiens. Lorsque ces hypothèses ne sont pas vérifiées, on peut alors recourir à l'approximation du filtre de Kalman étendu (avec plus ou moins de succès), ou choisir un modèle inexact, mais qui respecte les hypothèses « linéaire gaussien ».

Une approche alternative récente permet la mise en œuvre du filtrage statistique « exact » en contexte quelconque. Au lieu d'estimer l'espérance mathématique et la variance de la distribution des paramètres d'état conditionnellement aux observations, on génère une population de « particules » distribuées selon cette distribution. Ces particules sont propagées et mises à jour au cours du temps, et sont utilisées pour estimer, filtrer, prédire, ...

Le filtrage particulière ou méthode de Monte Carlo séquentielle est une technique très efficace pour estimer séquentiellement l'état caché d'un système dynamique non linéaire. Le calcul de cette estimation dépend de la densité de probabilité a posteriori de l'état caché sachant les observations.

Cependant, dans le cas d'un système dynamique non linéaire cette densité ne peut pas être déterminée analytiquement. Il faut utiliser des approximations numériques.

Le filtrage particulière approxime la densité a posteriori avec des échantillons pondérés, appelés particules, qui évoluent dans le temps selon les lois dynamiques du système considéré. Cette évolution permet l'estimation séquentielle de l'état caché.

Le filtrage particulière est donc une méthode globale qui repose sur une exploration de l'espace d'état du problème par des "particules" dont la dynamique évolue de façon aléatoire. L'ensemble de ces particules est distribué selon la probabilité du processus à estimer, conditionnelle aux observations délivrées par le ou les capteurs.

Ne nécessitant pas de résolution explicite des équations du problème, cette méthode est applicable quelle que soit la complexité de ces équations, notamment en termes de non linéarité et de non gaussianité.

Aucun modèle physique, aussi réaliste soit-il, ne lui est donc pas inaccessible.

Notre travail est basé sur le filtrage particulière, dans le chapitre suivant on va détailler le principe du filtrage particulière et les différentes versions de ce type de filtrage.

2.6 Estimation multi-modèles

Dans de nombreuses applications d'ingénierie, il s'agit de systèmes dynamiques non linéaires caractérisés par quelques modes (ou régimes) de fonctionnement possibles. Dans le domaine de poursuite, par exemple, cela s'applique aux cibles manœuvrantes, où les modèles de comportement du système (mouvement sans manœuvre, diverses manœuvres) sont appelés modes système [9]. Ces types de problèmes sont souvent désignés sous le nom de problèmes d'estimation de Markov ou d'état hybride [84] impliquant à la fois l'état cible à valeur continue et la variable régime à valeur discrète (mode).

Un système hybride à temps discret est décrit par les équations dynamiques et de mesures suivantes :

$$\mathbf{x}_k = f_{k-1}(\mathbf{x}_{k-1}, r_k, v_{k-1}) \quad (2.46)$$

$$z_k = h_k(\mathbf{x}_k, r_k, w_k) \quad (2.47)$$

Où r_k est la variable de régime (modèle) en vigueur pendant la période d'échantillonnage $(t_{k-1}, t_k]$, c'est-à-dire avec l'impact du nouveau modèle, r_{k+1} , à partir de t_k^+ . La variable régime est généralement modélisée par une chaîne de Markov du premier ordre de l'état s-homogène dans le temps, avec des probabilités transitoires.

$$\pi_{ij} = P\{r_k = j | r_{k-1} = i\} \quad (i, j) \in S \quad (2.48)$$

Où $S \triangleq \{1, 2, \dots, s\}$. La matrice de transition des probabilités (TMP) $\Pi = [\pi_{ij}]$ est une matrice de dimension $s \times s$ avec des éléments satisfaisants, elle est donnée par (2.49).

$$\pi_{ij} \geq 0 \quad \text{and} \quad \sum_{j=1}^s \pi_{ij} = 1 \quad (2.49)$$

Pour chaque $i, j \in S$. Les probabilités de régime initial sont données par :

$$\mu_i \triangleq P\{r_1 = i\} \quad (2.50)$$

Pour $i \in S$, Et sachant que

$$\mu_i \geq 0 \quad \text{et} \quad \sum_{i=1}^s \mu_i = 1 \quad (2.51)$$

Les autres termes des équations (2.46) et (2.47) ont été définis auparavant. Notez que si $r = 1$, (2.46) est identique à (2.2) et (2.47) est identique à (2.4). Notons également que la solution conceptuelle au problème de filtrage non linéaire défini par (2.46) et (2.47) est de nouveau donnée par (2.7) et (2.9), la seule différence étant que le vecteur d'état est maintenant un vecteur d'état hybride augmenté : $y_k = [\mathbf{x}_k^T, r_k]$. Pour compléter l'exhaustivité, nous donnons ici la solution récursive conceptuelle au problème d'estimation d'état hybride :

- Prédiction

$$p(\mathbf{x}_k, r_k = j | z_{k-1}) = \sum_i \pi_{ij} \int p(\mathbf{x}_k | \mathbf{x}_{k-1}, r_k = j) p(\mathbf{x}_{k-1}, r_{k-1} = i | z_{k-1}) d\mathbf{x}_{k-1} \quad (2.52)$$

- Mise à jour (Correction)

$$p(\mathbf{x}_k, r_k = j | z_k) = \frac{p(z_k | \mathbf{x}_k, r_k = j) p(\mathbf{x}_k, r_k = j | z_{k-1})}{\sum_j \int p(z_k | \mathbf{x}_k, r_k = j) p(\mathbf{x}_k, r_k = j | z_{k-1}) d\mathbf{x}_k} \quad (2.53)$$

Pour cette approche deux algorithmes des plus performants sont : l'algorithme multi-modèles interactifs (Interacting Multiple Model IMM) qui est exclusivement basé sur le filtrage de Kalman et l'algorithme dit de Rao-Blackwiltize qui fait appel à la fois au filtrage de Kalman et au filtrage particulière.

2.7 Modélisation des trajectoires de la cible

Divers modèles mathématiques sophistiqués du mouvement des cibles ont été développés au cours des trois dernières décennies, ils peuvent être par exemple trouvés dans [16] [9] [85].

Les filtres de poursuite sont des méthodes numériques qui nécessitent l'emploi de calculateurs. Les modèles dynamiques des cibles doivent donc être formulés par des équations discrètes pour permettre leur simulation sur ordinateur. En pratique, on peut soit partir des équations (différentielles) continues d'évolution de la cible ; ou bien modéliser directement sous forme discrète l'évolution de la cible.

2.7.1 Les modèles non-manouvrants

2.7.1.1 Modèle à vitesse constante (CV)

Chaque point se déplaçant dans un plan 3D peut être décrit par ses vecteurs de position et de vitesse 3D. Par exemple $x = [x, \dot{x}, y, \dot{y}, z, \dot{z}]'$ peut être utilisé comme vecteur d'état d'un tel point dans le système de coordonnées cartésiennes, où (x, y, z) sont les coordonnées de position suivant les axes x, y et z , respectivement, et $[\dot{x}, \dot{y}, \dot{z}]'$ est le vecteur vitesse. Lorsqu'une cible considérée comme une cible ponctuelle, le mouvement non manœuvrant est donc décrit par l'équation $\dot{x}(t) = 0$, où $x = [\dot{x}, \dot{y}, \dot{z}]'$. Notez que la direction z est traitée différemment parce qu'un mouvement non-manœuvrant est supposé dans le plan horizontal x - y . En pratique, cette équation idéale est généralement modifiée comme $\dot{x}(t) = v(t) \approx 0$, où $v(t)$ est un bruit blanc avec un effet négligeable sur x . Le modèle d'espace d'état correspondant est donné par :

$$\dot{x}(t) = \text{diag}[A_{CV}, 0]x(t) + \text{diag}[B_{CV}, 1]v(t) \quad (2.54)$$

Avec vecteur d'état $x = [x, \dot{x}, y, \dot{y}, z, \dot{z}]'$ et $v(t) = [v_x(t), v_y(t), v_z(t)]'$ est un processus de bruit blanc en temps continu avec la matrice de densité spectrale de puissance $\text{diag}[S_x, S_y]'$, $A_{CV} = \text{diag}[A_2, A_2]$ et $B_{CV} = \text{diag}[B_2, B_2]$ avec

$$A_2 = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}, B_2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (2.55)$$

L'équation équivalente en temps discret du modèle ci-dessus est donnée dans [9] [85].

$$\begin{aligned} x_{k+1} &= Fx_k + Gv_k = \text{diag}[F_{CV}, 1]x_k + \text{diag}[G_{CV}, T]v_k \\ &= \text{diag}[F_2, F_2, 1]x_k + \text{diag}[G_2, G_2, T]v_k \end{aligned} \quad (2.56)$$

$$\text{Où} \quad F_{CV} = \text{diag}[F_2, F_2], \quad G_{CV} = \text{diag}[G_2, G_2]$$

$$F_2 = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix} \quad G_2 = \begin{bmatrix} T^2/2 \\ T \end{bmatrix} \quad (2.57)$$

$v(t) = [v_x(t), v_y(t), v_z(t)]'$ est une séquence de bruit blanc en temps discret et T est l'intervalle d'échantillonnage. Notez que v_x et v_y correspondent respectivement aux "accélération" bruyantes selon les axes x et y , tandis que v_z correspond à la "vitesse" bruyante selon l'axe z . Si v est découplé entre ses composantes, alors le mouvement non-manœuvrant modélisé par les modèles ci-dessus est découplé entre les directions x, y et z . Dans ce cas, la covariance du terme de bruit dans (2.56) est donnée par l'équation suivante

$$\text{cov}(Gv_k) = \text{diag}[\text{var}(v_x)Q_2, \text{var}(v_y)Q_2, \text{var}(v_z)]$$

$$Q_2 = \begin{bmatrix} T^4/4 & T^3/2 \\ T^3/2 & T^2 \end{bmatrix} \quad (2.58)$$

Ce modèle est défini directement en temps discret et n'est pas entièrement équivalent au modèle en temps continu ci-dessus.

L'équivalent en temps discret du modèle en temps continu ci-dessus est donné dans [9].

$$x_{k+1} = \text{diag}[F_2, F_2, 1]x_k + v_k \quad (2.59)$$

Où

$$\text{cov}(v_k) = \text{diag} \left[\frac{s_x}{T} \tilde{Q}_2, \frac{s_y}{T} \tilde{Q}_2, \frac{s_z}{T} \tilde{Q}_2 \right] \text{ et } Q_2 = \begin{bmatrix} T^4/3 & T^3/2 \\ T^3/2 & T^2 \end{bmatrix} \quad (2.60)$$

Notez la différence entre l'équivalent temps discret (2.59) et l'équivalent temps discret direct (2.56). Dans un scénario 2-D où l'altitude z n'est pas prise en compte, les modèles ci-dessus prennent respectivement la forme la plus connue suivante,

$$\begin{aligned} \dot{x}(t) &= A_{CV}x(t) + B_{CV}v(t) \\ x_{k+1} &= F_{CV}x_k + G_{CV}v_k \\ x_{k+1} &= F_{CV}x_k + v_k \end{aligned} \quad (2.61)$$

Les modèles ci-dessus (2.54), (2.56), (2.59) et (2.61) sont connus sous le nom des modèles à vitesse constante (CV) en temps continu et en temps discret ou plus précisément, "modèles à vitesse quasi constante". L'équation (2.61) est considérée comme un " (petit) modèle d'accélération blanc". Puisque les accélérations dans les directions x et y sont modélisé comme bruit blanc faible. Le terme "(presque) modèle à vitesse constante " souligne que ceux-ci ont des accélérations faibles.

2.7.2 Les modèles manouvriers avec les coordonnées-découplées

L'entrée de commande u responsable au manouvre de la cible est principalement de nature déterministe et le plus souvent inconnue. On peut le modéliser comme un processus déterministe inconnu et d'estimer ce processus à partir des données de mesure pendant la poursuite. En raison d'un manque de connaissance de sa dynamique, ce processus inconnu est souvent supposé être constant par morceaux et être traité comme un paramètre inconnu dans le temps.

Les modèles de cette classe proposés dans la littérature peuvent être en grande partie classés en trois groupes comme suit.

- Modèles de bruit blanc : l'entrée de commande est modélisée en bruit blanc. Cela comprend les modèles à accélération constante et polynomiaux.
- Modèles du processus de Markov : l'entrée de commande est modélisée comme un processus de Markov, qui a une autocorrélation temporelle. Cela inclut le célèbre modèle Singer, ses différentes extensions, et quelques autres modèles.
- Modèles du processus de saut semi-Markov : l'entrée de commande est modélisée comme un processus de saut semi-Markov.

La plupart des manœuvres de la cible sont couplées entre différentes coordonnées. Par souci de simplicité, cependant, de nombreux modèles de manœuvre développés partent du principe

que ce couplage de coordonnées est faible et qu'il peut être négligé. C'est particulièrement le cas pour ceux qui modélisent l'entrée de commande u comme un processus aléatoire. Par conséquent, nous n'avons qu'à considérer une direction de coordonnées génériques.

Soit x , \dot{x} et \ddot{x} la position, la vitesse et l'accélération de la cible, respectivement. Plus précisément,

$$\ddot{x}(t) = a(t) \quad (2.62)$$

Dans ce paragraphe, le vecteur d'état est toujours considéré comme $x = [x, \dot{x}, \ddot{x}]'$.

2.7.2.1 Modèle à accélération constante (CA) (Wiener-Process Acceleration Model)

Le modèle le plus simple est celui d'accélération du processus de Wiener "Wiener-process acceleration model". Il suppose que l'accélération est un processus de Wiener [9] [85], ou plus généralement, l'accélération est un processus avec des incréments indépendants, qui n'est pas nécessairement un processus de Wiener. On l'appelle aussi le modèle à accélération constante (CA) ou plus précisément le "modèle d'accélération quasi constante".

Ce modèle a deux versions couramment utilisées. Le premier, appelé "White-noise jerk model", suppose que la dérivée d'accélération (ie, jerk) $\dot{a}(t)$ est un processus indépendant (bruit blanc) $v(t) : \dot{a}(t) = v(t)$, avec une densité spectrale de puissance S_v . La représentation de l'espace d'états correspondant est $\dot{x}(t) = A_3x(t) + B_3v(t)$, où

$$A_3 = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}, B_3 = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \quad (2.63)$$

L'équation équivalente en temps discret est donnée par

$$x_{k+1} = F_3x_k + v_k, F_3 = \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix} \quad (2.64)$$

Où

$$Q = cov(v_k) = S_v Q_3, \quad Q_3 = \begin{bmatrix} T^5/20 & T^4/8 & T^3/6 \\ T^4/8 & T^3/3 & T^2/2 \\ T^3/6 & T^2/2 & T \end{bmatrix} \quad (2.65)$$

Notez que S_v est la densité spectrale de puissance du bruit blanc $v(t)$ à temps continu. La deuxième version peut être appelée modèle d'accélération de la séquence de Wiener "Wiener-sequence acceleration model". Il suppose que l'incrément d'accélération est un processus indépendant (bruit blanc). Un incrément d'accélération sur une période de temps est l'intégrale de la secousse sur la période. Ce modèle est exprimé en temps discret de la manière suivante,

$$x_{k+1} = F_3x_k + G_3v_k, G_3 = \begin{bmatrix} T^2/2 \\ T \\ 1 \end{bmatrix} \quad (2.66)$$

Notez que la covariance du bruit est différente de celle du modèle de jerk de bruit blanc :

$$Q = \text{cov}(G_3 v_k) = \text{var}(v_k) \begin{bmatrix} T^4/4 & T^3/2 & T^2/2 \\ T^3/2 & T^2/2 & T \\ T^2/2 & T & 1 \end{bmatrix} \quad (2.67)$$

Le modèle ci-dessus est simple, par contre les manœuvres réelles ont rarement des accélérations (presque) constantes qui sont découplées dans les directions de coordonnées.

Comme expliqué précédemment, un modèle à temps continu est plus précis que ses versions à temps discret pour la plupart des situations pratiques puisqu'une cible se déplace continuellement dans le temps. L'hypothèse du modèle direct en temps discret selon laquelle l'incrément d'accélération $\Delta a_k = a_{k+1} - a_k = a(t_{k+1}) - a(t_k)$ est indépendant sur différents intervalles d'échantillonnage est utilisée pour simplicité et sa traçabilité mathématique.

2.7.3 Les modèles manouvrants du mouvement horizontal à 2-D

La majorité des modèles de manœuvre des cibles 2-D et 3-D sont des modèles de mouvement à rotation (à virage). Ces modèles sont généralement établis en fonction de la cinématique de la cible, contrairement à ceux présentés dans la section (2.7.1) précédente qui sont basés sur des processus aléatoires. C'est compréhensible car les processus aléatoires sont plus naturels pour modéliser la corrélation temporelle que la description de trajectoires spatiales où la cinématique est un outil plus approprié. Les modèles de mouvement horizontal 2-D sont décrits dans cette section, généralement dans un ordre allant du plus simple au plus sophistiqué.

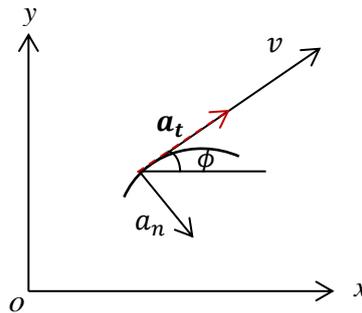


Figure 2-3 La géométrie du mouvement à 2-D d'une cible

Divers modèles cinématiques proposés pour suivre une cible se déplaçant dans le plan horizontal peuvent être composés à partir du modèle de mouvement curvilinéaire standard suivant la cinématique (voir Figure 2-3) :

$$\dot{x}(t) = v(t)\cos\phi(t) \quad (2.68)$$

$$\dot{y}(t) = v(t)\sin\phi(t) \quad (2.69)$$

$$\dot{v}(t) = a_t(t) \quad (2.70)$$

$$\dot{\phi}(t) = a_n(t)/v(t) \quad (2.71)$$

où (x, y) , v , ϕ sont respectivement la position de la cible en coordonnées cartésiennes, la vitesse au sol (vitesse relative plus la vitesse du vent) et l'angle de cap. a_t et a_n sont respectivement la tangente de la cible (le long de la piste) et les accélérations normales dans le

plan horizontal. Ce modèle est assez général : il tient compte des accélérations transversales et croisées et se réduit aux cas spéciaux suivants :

- $a_n = 0, a_t = 0$: rectiligne, mouvement CV,
- $a_n = 0, a_t \neq 0$: mouvement rectiligne accéléré (mouvement CA si $a_t = \text{constant}$),
- $a_n \neq 0, a_t = 0$: circulaire, mouvement à vitesse constante (mouvement CT si $a_n = \text{constant}$).

Le dernier cas ci-dessus avec une constante a_n non nulle, qui correspond à une vitesse constante et une vitesse de angulaire constante, est appelé modèle de virage coordonné "coordinate turn model" (CT) dans la poursuite de cible.

2.7.3.1 Modèle de virage (CT) avec taux de rotation connu

Ce type de modèle suppose que la cible se déplace avec une vitesse (presque) constante v et une vitesse angulaire connue (presque) constante Ω . Par exemple, à partir de l'équation (2.68) jusqu'à (2.71), obtient un vecteur d'état $x = [x, \dot{x}, y, \dot{y}]$ en coordonnées cartésiennes. Sachant que, le mouvement circulaire de la cible est décrit par l'équation suivante :

$$\dot{x}(t) = \begin{bmatrix} \dot{x}(t) \\ -\Omega \dot{y}(t) \\ \dot{y}(t) \\ \omega \dot{x}(t) \end{bmatrix} + Bv(t) = A(\Omega)x(t) + Bv(t) \quad (2.72)$$

avec

$$A(\Omega) = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & -\Omega \\ 0 & 0 & 0 & 1 \\ 0 & \Omega & 0 & 0 \end{bmatrix}, \quad (\Omega) = \begin{bmatrix} 0 & 0 \\ 1 & 0 \\ 0 & 0 \\ 0 & 1 \end{bmatrix}$$

où le bruit blanc $v = [v_x, v_y]'$ d'une densité spectrale de puissance de diagonale $\text{diag}[S_v, S_v]$. Ce modèle CT est linéaire puisque la vitesse angulaire Ω est connue. Sa description est donnée via l'équation suivante :

$$x_{k+1} = F_{CT}(\Omega)x_k + v_k = \begin{bmatrix} 1 & \frac{\sin\Omega T}{\Omega} & 0 & -\frac{1-\cos\Omega T}{\Omega} \\ 0 & \cos\Omega T & 0 & -\frac{\sin\Omega T}{\Omega} \\ 0 & \frac{1-\cos\Omega T}{\Omega} & 1 & \frac{\sin\Omega T}{\Omega} \\ 0 & \sin\Omega T & 0 & \cos\Omega T \end{bmatrix} x_k + v_k \quad (2.73)$$

Où

$$Q = \text{cov}(v_k) = \begin{bmatrix} \frac{2(\Omega T - \sin\Omega T)}{\Omega^3} & \frac{1-\cos\Omega T}{\Omega^2} & 0 & \frac{\Omega T - \sin\Omega T}{\Omega^2} \\ \frac{1-\cos\Omega T}{\Omega^2} & T & -\frac{\Omega T - \sin\Omega T}{\Omega^2} & 0 \\ 0 & -\frac{\Omega T - \sin\Omega T}{\Omega^2} & \frac{2(\Omega T - \sin\Omega T)}{\Omega^3} & \frac{1-\cos\Omega T}{\Omega^2} \\ \frac{\Omega T - \sin\Omega T}{\Omega^2} & 0 & \frac{1-\cos\Omega T}{\Omega^2} & T \end{bmatrix} \quad (2.74)$$

L'équation d'état en temps discret est donnée par (2.73), où v_k est le bruit d'état avec une covariance $cov(v_k)$ donnée par (2.74).

2.8 Conclusion

Dans ce chapitre, nous avons détaillé la problématique du filtrage non-linéaire utilisant d'état l'estimation d'état d'un processus markovien observé à partir d'un processus conditionnellement indépendant. Ensuite, pour résoudre ce problème, nous avons présenté les différentes solutions analytiques. Nous avons commencé par la méthode optimale pour un espace d'état discret et fini, pour les modèles linéaires gaussiens (comme le filtre de Kalman). D'autre part, il existe d'autres méthodes sous-optimales comme le filtre de Kalman étendu qui utilise une linéarisation d'un système gaussien et il est très efficace et donne des bons résultats pour les systèmes faiblement non-linéaires ; ensuite le filtre de Kalman sans parfum échantillonne le système non-linéaire d'une manière déterministe et améliore légèrement les résultats dans le cas d'un système fortement non-linéaire. Enfin, Une nouvelle méthode sera détaillée dans le chapitre suivant : les méthodes séquentielles de Monte Carlo. Elles sont efficaces au problème du filtrage non-linéaire non-gaussien. Ce type de méthodes, appelées filtrage particulaire est utilisé (ou méthode séquentielle de Monte Carlo (MSMC)) aux problèmes de poursuite dans un contexte track before detect qui est le but de cette thèse.

3. LE FILTRAGE PARCULARE

3. LE FILTRAGE PARCULARE.....	58
3.1 Introduction	59
3.2 La méthode de Monte-Carlo	59
3.3 L'échantillonnage de Monte-Carlo standard.....	60
3.3.1 L'échantillonnage de Monte-Carlo pondéré (échantillonnage d'importance)	61
3.4 L'échantillonnage d'importance séquentiel (SIS).....	62
3.4.1 Dégénérescence de l'algorithme SIS	64
3.5 Ré-échantillonnage	65
3.6 Filtrage particulaire générique	67
3.7 Choix de la densité d'importance sous-optimale	69
3.8 Versions du filtrage particulaire	70
3.8.1 Le filtre particulaire SIR (Ré-échantillonnage Séquentiel par Importance des Échantillons)	70
3.8.2 Filtre particulaire auxiliaire (ASIR)	71
3.8.3 Le filtre particulaire régularisé (RPF)	73
3.8.4 Filtre particulaire à modèle multiple (MMPF)	75
3.9 Conclusion.....	77

Ce chapitre présente d'une part les méthodes de Monte-Carlo et d'autre part le filtrage particulaire ainsi que ses différentes versions utilisées dans le domaine de la poursuite de cibles et spécialement dans l'Approche Track-Before-Detect.

3.1 Introduction

Dans le chapitre précédent, nous avons détaillé le filtrage bayésien, qui consiste à faire l'estimation d'un processus de Markov via une équation d'observation (équation de mesure). La solution récursive donnée par les équations de prédiction et correction est utilisée pour éviter le stockage des mesures précédentes. Cette réclusion est aussi considérée comme une solution du filtrage non linéaire optimal si $x_{1:k}$ est markovien et $z_{1:k}$ est indépendant conditionnellement à $x_{1:k}$. Mais pour trouver de bons estimateurs à implémenter, il faut que le système soit linéaire et gaussien avec un espace d'état discret et fini. La non-linéarité de l'équation d'état et de l'équation de mesure rend impossible le calcul analytique des intégrales et des multiplications donnant les estimateurs. Nous avons présenté dans le chapitre 2 précédent plusieurs versions sous optimales de l'algorithme de filtrage de Kalman utilisé dans le cas d'un système non-linéaire et d'un espace d'état continu. Ce type d'algorithmes souffrent de plusieurs inconvénients car ils doivent faire le calcul des matrices jacobiniennes $\frac{\partial f}{\partial x}$ et $\frac{\partial h}{\partial x}$ pour approcher la densité a posteriori $p(x_k|z_{1:k})$ par une distribution gaussienne. Pour les applications de poursuite multi-cibles ou dans un milieu fortement bruité (poursuite dans le fouillis), les algorithmes précédents ne peuvent pas résoudre le problème car dans le premier cas (multi-cibles) la densité $p(x_k|z_{1:k})$ peut prendre une forme multi-modèles. Ainsi que, la linéarisation locale par les calculs de jacobiniennes ne sont pas valides dans un bruit élevé (faible rapport signal sur bruit) et pour les cibles fortement manœuvrantes. En dehors des techniques présentées précédemment, il existe des méthodes numériques totalement différentes comme la méthode de Monte-Carlo (filtrage particulaire). Dans ce chapitre, nous présentons une étude théorique des approches du filtrage bayésien récursif basées sur l'échantillonnage de Monte-Carlo dit aussi filtrage particulaire. Aussi sont présentées différentes versions du filtrage particulaire qui sont utilisées par la suite, et notamment dans le cadre de l'application traitée.

3.2 La méthode de Monte-Carlo

Pendant la seconde guerre mondiale les chercheurs ont lancé le projet Manhattan pour réaliser la première bombe atomique. Von Neumann, Stanislaw, Fermi et Ulam ont proposé d'utiliser les méthodes de Monte-Carlo pour simuler les réactions nucléaires d'une manière aléatoire. Cette méthode prend le nom de quartier "Monte Carlo" de la principauté de Monaco qui abrite le célèbre casino. Par la suite, cette méthode s'est généralisée dans plusieurs domaines : physique, économie, sondage, etc....

Dans les années 50 l'idée de l'estimation séquentielle de Monte-Carlo (SMC) sous la forme d'un échantillonnage d'importance récursif est proposé dans le domaine statistique [67]. Mais par la suite, dans les années 60 et 70 cette méthode a continué d'être utilisée mais sporadiquement [86][87], jusqu'à où elle est devenue négligeable. Cela était dû à la puissance modeste de moyens de calcul disponible à cette époque. Sachant que les premières applications ont été basées sur l'échantillonnage d'importance séquentiel simple. Par contre le vrai développement de la méthode SMC est venu après l'intégration de la méthode de ré-

échantillonnage, qui est couplé avec les ordinateurs toujours plus rapides, a donné son utilité pratique au filtrage particulaire [88].

Au début des années 90 [68][89], les chercheurs ont découvert le filtrage particulaire. Ce chapitre est basé sur la présentation uniforme du filtrage particulaire en utilisant la notion d'échantillonnage d'importance [53].

3.3 L'échantillonnage de Monte-Carlo standard

Cette section est consacrée à la théorie utilisée dans les algorithmes de filtrage particulaire. L'objectif de la méthode de Monte-Carlo est d'approximer une distribution de probabilité difficile à calculer analytiquement en utilisant des échantillons discrets simulés. Par exemple, dans le filtrage récursif bayésien, on peut utiliser cette méthode d'échantillonnage pour l'approximation des intégrales de grands nombres qui apparaît dans l'équation de prédiction $p(x|z_{1:k-1})$ (Chapman-Kolmogorov). Après l'évaluation de la densité a posteriori $p(x|z)$, on peut calculer des estimateurs de la forme suivante :

$$I = \int f(x)\pi(x)dx \quad (3.1)$$

Où $x \in \mathbb{R}^{n_\infty}$ et $\pi(x)$ est donnée comme une densité de probabilité tel que $\pi(x) \geq 0$ et $\int \pi(x)dx = 1$.

Pour calculer l'intégrale I l'approche de Monte-Carlo utilise des réalisations indépendantes d'une variable aléatoire distribuée suivant la loi a posteriori $\{x^i; i = 1, \dots, N\}$ dans le but de trouver les moyennes empiriques.

$$I_N = \frac{1}{N} \sum_{i=1}^N f(x^i) \quad (3.2)$$

Cette approximation suit la loi de grands nombres avec une variance finie et une moyenne à espérance commune entre les variables aléatoires données par :

$$\lim_{N \rightarrow \infty} I_N = I \quad (3.3)$$

Si les échantillons x^i sont indépendants alors I_N est une estimation sans biais qui suit la loi des grands nombres et qui converge vers I . Si la variance de $f(x)$ est donnée par l'expression suivante :

$$\sigma^2 = \int (f(x) - I)^2 \pi(x) dx \quad (3.4)$$

Donc on peut appliquer le théorème central limite et noter que l'erreur d'estimation converge en distribution gaussienne comme suit :

$$\lim_{N \rightarrow \infty} \sqrt{N}(I_N - I) \sim \mathcal{N}(0, \sigma^2) \quad (3.5)$$

L'erreur de l'estimation Monte-Carlo $e = I_N - I$ est de l'ordre de $O(N^{-1/2})$. Ce qui signifie que le taux de convergence de l'estimation est indépendant de la dimension de l'espace d'intégration, ceci contrairement aux intégrales numériques déterministes. Cette propriété avantageuse et importante est due au choix des échantillons $\{x^i; i = 1, \dots, N\}$, parce qu'ils font partie des régions de l'espace d'état les plus probables pour le résultat d'intégration.

Malheureusement, quand la dimension de l'espace d'état croît, le nombre de tirages N augmente d'une manière importante (largement).

L'approximation de MC est considérée comme une technique d'échantillonnage aléatoire, dans ce cas il faut savoir générer des échantillons indépendants $\{x^i; i = 1, \dots, N\}$ selon la distribution a posteriori $\pi(x)$. Malheureusement, il est rare qu'on sache l'échantillonner directement. Une forme complexe de la densité $\pi(x)$, à plusieurs variables ou connue à une constante peut rendre l'intégration MC difficile. Par contre, il existe d'autres techniques qui utilisent des densités arbitraire $q(x|z)$ qui s'appelle densité instrumentale (proposal distribution en anglais), dont le support contient celui de $\pi(x)$ et selon laquelle il est facile d'échantillonner. Une nouvelle technique d'échantillonnage a été proposée par [90] et elle est nommée méthode d'acceptation/rejet qui permet d'accepter ou de rejeter les échantillons générés selon la loi $q(x|z)$ avec une probabilité d'acceptation bien désignée. La méthode est bien détaillée dans la référence [91].

L'inconvénient majeur du filtrage particulaire [15] est le temps de calcul très élevé en raison du rejet d'un grand nombre d'échantillons et qui demande des ressources informatiques très avancées. Pratiquement, cette méthode est inefficace et demande la connaissance de $\max_x \{p(x|z)|q(x|z)\}$. Metropolis et al [92] ont proposé la nouvelle méthode d'échantillonnage nommée Metropolis-Hasting et qui est développée plus tard par Hastings [93]. Cette technique est basée sur la simulation d'une chaîne de Markov avec une distribution stationnaire $p(x|z)$. L'algorithme Metropolis-Hasting est inadéquat pour plusieurs applications en temps réel. Cet algorithme exige une longue durée d'établissement (burn-in period) pour que la chaîne obtienne sa distribution stationnaire. De plus, il génère des échantillons dépendants.

3.3.1 L'échantillonnage de Monte-Carlo pondéré (échantillonnage d'importance)

Cette section présente une autre approche de l'intégration de Monte-Carlo nommée par méthode d'échantillonnage d'importance [94]. C'est cette méthode qui sera utilisée dans l'application traitée. Comme on l'a déjà mentionné précédemment, l'échantillonnage idéal se fait directement selon la loi a posteriori afin d'estimer I en utilisant (3.1). On considère qu'on peut faire la simulation des échantillons selon une densité d'importance $q(x|z)$ et la pondération de l'ensemble de ces échantillons rend l'estimation MC encore possible. La densité d'importance doit avoir un support contenant celui de loi a posteriori c-à-d cette densité satisfait la condition suivante :

$$\pi(x) > 0 \Rightarrow q(x) > 0 \quad \text{pour tout } x \in \mathbb{R}^{n_\infty} \quad (3.6)$$

L'échantillonnage d'importance valable si la condition (3-6) est vérifiée et dans ce cas l'intégrale de l'équation (3-1) peut s'exprimer comme suit :

$$I = \int f(x)\pi(x)dx = \int f(x) \frac{\pi(x)}{q(x)} q(x)dx \quad (3.7)$$

En sachant que que $\frac{\pi(\mathbf{x})}{q(\mathbf{x})}$ admet une borne supérieure. Une estimation de Monte Carlo de I génère $N \gg 1$ échantillons indépendants $\{\mathbf{x}^i; i = 1, \dots, N\}$ selon la densité $q(\mathbf{x})$ et donner la somme pondérée suivante :

$$I_N = \frac{1}{N} \sum_{i=1}^N f(\mathbf{x}^i) \tilde{\omega}(\mathbf{x}^i) \quad (3.8)$$

Où les poids d'importance $\tilde{\omega}(\mathbf{x}^i)$ sont donnés par :

$$\tilde{\omega}(\mathbf{x}^i) = \frac{\pi(\mathbf{x}^i)}{q(\mathbf{x}^i)} \quad (3.9)$$

Si le facteur de normalisation de la densité $\pi(\mathbf{x})$ est inconnu, on a besoin normaliser les poids d'importance. Donc, on estime I_N de la manière suivante :

$$I_N = \frac{\frac{1}{N} \sum_{i=1}^N f(\mathbf{x}^i) \tilde{\omega}(\mathbf{x}^i)}{\frac{1}{N} \sum_{i=1}^N \tilde{\omega}(\mathbf{x}^i)} = \sum_{i=1}^N f(\mathbf{x}^i) \omega(\mathbf{x}^i) \quad (3.10)$$

où les poids d'importance normalisés sont donnés par :

$$\omega(\mathbf{x}^i) = \frac{\tilde{\omega}(\mathbf{x}^i)}{\sum_{j=1}^N \tilde{\omega}(\mathbf{x}^j)} \quad (3.11)$$

3.4 L'échantillonnage d'importance séquentiel (SIS)

Pour résoudre le problème de filtrage non-linéaire récursivement plusieurs méthodes ont été proposées précédemment dans le chapitre 2 et parmi ces méthodes l'échantillonnage d'importance. Durant cette dernière décennie, la majorité des filtres extraient de l'approche MC sont basés sur L'algorithme d'échantillonnage séquentiel par importance (SIS en anglais) [95] [89]. Cette approche est connu sous le nom de filtrage particulaire (PF) [88], et aussi par "Bootstrap filtering"[68] et "condensation algorithm"[96]. C'est une technique qui utilise l'approximation de Monte-Carlo pour implémenter un filtre bayésien récursif. L'idée principale est de représenter la densité a posteriori par un ensemble d'échantillons aléatoires pondérés pour calculer les estimateurs souhaités. Lorsque le nombre d'échantillon augmente d'une manière importante, l'approximation de Monte-Carlo correspond à la description fonctionnelle usuelle de la densité a posteriori, et donc le filtre SIS approxime l'estimateur bayésien optimal.

On considère une mesure aléatoire $\{\mathbf{x}_{0:k}^i, \omega_k^i\}$ caractérise la densité conjointe a posteriori $p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k})$, où ω_k^i est le poids d'importance normalisé correspondant à l'échantillon $\mathbf{x}_{0:k}^{(i)}$. La densité conjointe a posteriori à l'instant k est alors exprimée par [95]:

$$p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}) \approx \sum_{i=1}^N \omega_k^i \delta(\mathbf{x}_{0:k} - \mathbf{x}_{0:k}^i) \quad (3.12)$$

Le choix des poids normalisés ω_k^i se base sur le principe d'échantillonnage d'importance décrit dans la section précédente. Dans le cas où les échantillons $\mathbf{x}_{0:k}^i$ sont générés selon une densité d'importance $q(\mathbf{x}_{0:k} | \mathbf{z}_k)$, alors l'équation (3.9) nous permet d'écrire :

$$\omega_k^i \propto \frac{p(\mathbf{x}_{0:k}^i | \mathbf{z}_{1:k})}{q(\mathbf{x}_{0:k}^i | \mathbf{z}_{1:k})} \quad (3.13)$$

Alors, l'extension séquentielle de l'algorithme d'échantillonnage d'importance doit transformer la mesure aléatoire $\{x_{0:k}^i, \omega_{k-1}^i\}_{i=1}^N$ en $\{x_{0:k}^i, \omega_k^i\}_{i=1}^N$ jusqu'à la réception de la mesure z_k . Si la loi d'importance se factorise comme suit :

$$q(x_{0:k}|z_{1:k}) \triangleq q(x_k|x_{0:k-1}, z_k)q(x_{0:k-1}|z_{1:k-1}) \quad (3.14)$$

Un échantillon $x_{0:k}^i \sim q(x_{0:k}|z_{1:k})$ est obtenu alors à partir de la procédure simple suivante :

- Générer $x_k^i \sim q(x_{0:k}|z_{1:k})$
- Effectuer la concaténation $x_{0:k}^i = \{x_{0:k-1}^i, x_k^i\}$

Sans l'étape de factorisation dans l'équation (3.14), on doit échantillonner l'état précédent entier x_{k-1} afin d'avoir des échantillons selon la loi $q(x_{0:k}^i|z_{1:k})$. Lorsque le nombre des échantillons k augmente, toute application en temps réel devient impossible. Après, l'étape de factorisation dans (3.14), on a besoin de générer N vecteurs d'état à chaque nouvelle mesure reçu. Ainsi que le but de la factorisation de la distribution d'importance est de simplifier la forme des poids d'importance. Selon la loi de bayes l'équation de mise à jour des poids est donnée par l'expression suivante :

$$p(x_{0:k}|z_{1:k}) = \frac{p(z_k|x_{0:k}, z_{1:k-1})p(x_{0:k}|z_{1:k-1})}{p(z_k|z_{1:k-1})} = \frac{p(z_k|x_{0:k}, z_{1:k-1})p(x_k|x_{0:k-1}, z_{1:k-1})p(x_{0:k-1}|z_{1:k-1})}{p(z_k|z_{1:k-1})} \quad (3.15)$$

Pour un processus markovien x conditionner par le processus z , l'équation (3.15) s'écrit :

$$p(x_{0:k}|z_{1:k}) = \frac{p(z_k|x_{0:k})p(x_k|x_{1:k-1})}{p(z_k|z_{1:k-1})}p(x_{0:k-1}|z_{1:k-1}) \quad (3.16)$$

En remplaçant (3.14) et (3.16) dans (3.13), donc l'équation de mise à jour des poids peut s'écrire sous la forme suivante :

$$\omega_k^i \propto \frac{p(z_k|x_{0:k}^i, z_{1:k-1})p(x_k^i|x_{k-1}^i)p(x_{0:k-1}^i|z_{1:k-1})}{p(z_k|z_{1:k-1})q(x_k^i|x_{0:k-1}^i, z_{1:k})q(x_{0:k-1}^i|z_{1:k-1})} \propto \omega_{k-1}^i \frac{p(z_k|x_{0:k}^i, z_{1:k-1})p(x_k^i|x_{k-1}^i)}{p(z_k|z_{1:k-1})q(x_k^i|x_{0:k-1}^i, z_{1:k})} \quad (3.17)$$

Si les distributions des mesures dépend que de l'état courant on peut remplacer $p(z_k|x_{0:k}^i, z_{1:k-1})$ par $p(z_k|x_k^i)$. on peut écrire $p(z_k|x_{0:k}^i, z_{1:k-1}) \triangleq p(z_k|x_k^i)$, donc la densité d'importance ne dépend que de x_{k-1} et z_k . Dans le cas où on a besoin d'une estimation d'état filtrée de la densité a posteriori marginale $p(x_k|z_{1:k})$ à chaque instant. Donc il faudra stocker x_{k-1}^i seulement et on peut négliger les états précédentes comme $x_{0:k-2}$ et l'historique des mesures $z_{1:k-1}$. Les nouveaux poids sont alors donnés par :

$$\omega_k^i \propto \omega_{k-1}^i \frac{p(z_k|x_k^i)p(x_k^i|x_{k-1}^i)}{q(x_k^i|x_{k-1}^i, z_k)} \quad (3.18)$$

La densité d'importance $q(x_k|x_{k-1}, z_k)$ est indépendante aux observations $z_{1:k-1}$. Donc on peut implémenter l'équation (3.18) récursivement. L'algorithme SIS approxime la densité a posteriori marginale $p(x_k|z_{1:k})$ de comme suit :

$$p(x_k | z_{1:k}) \approx \sum_{i=1}^N \omega_k^i \delta(x_k - x_k^i) \quad (3.19)$$

Où ω_k^i sont les poids d'importance normalisés donnés par l'équation (3.18). On peut montrer que lorsque $N \rightarrow \infty$, l'approximation de la densité a posteriori marginale (3.19) se rapproche de la vraie valeur de la densité a posteriori $p(x_k | z_{1:k})$. Le Filtrage par l'algorithme SIS se compte sur la propagation récursive des poids d'importance ω_k^i et les points de support x_k^i lors de la réception de chaque mesure. Le pseudo-code l'algorithme SIS est présenté dans la table 3-1.

$$\left[\{x_k^i, \omega_k^i\}_{i=1}^N \right] = SIS \left[\{x_{k-1}^i, \omega_{k-1}^i\}_{i=1}^N, z_k \right]$$

- Pour $i = 1:N$
 - Prédiction : Générer $x_k^i \sim q(x_k | x_{k-1}^i, z_k)$
 - Correction : Calculer les poids d'importance (~~2-20~~) (3-18)

$$\tilde{\omega}_k^i = \omega_{k-1}^i \frac{p(z_k | x_k^i) p(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{k-1}^i, z_k)}$$

- Fin pour
 - Calculer la somme des poids : $t = SOMME \left[\{\tilde{\omega}_k^i\}_{i=1}^N \right]$
 - pour $i =: N$
 - Normalisation : $\omega_k^i = \frac{\tilde{\omega}_k^i}{t}$
 - Fin pour
-

Table 3-1 Pseudo code du filtrage par l'algorithme SIS

Cet algorithme est basé sur le choix critique de la densité d'importance, et il est la base des majorités des filtres particuliers.

3.4.1 Dégénérescence de l'algorithme SIS

On a présenté l'algorithme d'échantillonnage d'importance séquentielle dans la section précédente SIS. L'inconvénient de cet algorithme qui rend son implémentation difficile est que la variance inconditionnelle des vrais poids d'importance ne peut pas décroître au cours du temps. L'effet indésirable de l'augmentation de la variance influe sur la pertinence et mène à un problème grave qui s'appelle problème de dégénérescence. Pratiquement, la dégénérescence s'exprime par l'évolution des particules au cours du temps ç.à.d à un certain temps toute les particules vont avoir des poids normalisés sauf une, elle va avoir un poids élevé. Ceci est néfaste pour deux causes :

- La première raison dépend de la qualité de la mesure aléatoire $\sum_{i=1}^N \omega_k^i \delta(x_k - x_k^i)$ qui peut se dégrader plus les poids deviennent égaux à zéro.

La deuxième dépend de capacité de calcul, On a pas besoin d'utiliser des calculateurs puissants pour calculer des points de support et leurs poids $\{x_k^i, \omega_k^i\}$, dont la contribution aux estimations produites par le filtre est négligeables.

Dans le filtrage SIS, on ne peut pas empêcher la dégénérescence, donc ce point est resté pour longtemps le grand inconvénient des méthodes de Monte-Carlo séquentielles. Une solution de ce problème est proposé dans [97] traduit par la mesure de la taille effective d'échantillons N_{eff} et estimée comme suit:

$$\hat{N}_{eff} = \frac{1}{\sum_{i=1}^N (\omega_k^i)^2} \quad (3.20)$$

Où ω_k^i est le poids d'importance normalisé. Il est facile de vérifier que $1 \leq N_{eff} \leq N$ avec les deux conditions suivantes:

- si les poids sont uniformes (i.e., $\omega_k^i = \frac{1}{N}$ pour $i = 1, \dots, N$) alors $N_{eff} = N$.
- si $\exists j \in \{1, \dots, N\}$ tel que $\omega_k^j = 1$, et $\omega_k^i = 0$ pour tout $i \neq j$, alors $N_{eff} = 1$. Donc une petite valeur de N_{eff} indique une dégénérescence sévère et vice versa. Ainsi, \hat{N}_{eff} est un indicateur efficace pour surveiller la dégénérescence de l'algorithme SIS. Après chaque mise à jour, N_{eff} est calculé et comparé à un certain seuil N_{th} . Un ré-échantillonnage a lieu quand N_{eff} tombe au-dessous du seuil N_{th} .

La section suivante présente l'étape de ré-échantillonnage qui va être utilisé pour traiter le problème de dégénérescence dans l'algorithme SIS.

3.5 Ré-échantillonnage

Le ré-échantillonnage est une étape importante dans l'algorithme SIS pour traiter le problème de dégénérescence (quand $N_{eff} < N_{th}$). Le principe de fonctionnement de cette technique est basé sur la redistribution des particules et de multiplier ensuite les particules à lourdes poids pour remplacer les particules faibles. Après la redistribution des particules, l'estimation deviendra plus appropriée car plus de particules se présentent pour décrire la région pertinente de l'espace d'état. Cette phase s'exprime par la fonction suivante :

$$\{x_k^i, \omega_k^i\}_{i=1}^N \rightarrow \{x_k^{i*}, 1/N\}_{i=1}^N \quad (3.21)$$

On génère un nouveau ensemble d'échantillons à partir de N tirages indépendant selon l'approximation discrète de la densité approximative $p(x_k | z_{1:k})$ donnée par :

$$p(x_k | z_k) \approx \sum_{i=1}^N \omega_k^i \delta(x_k - x_k^i) \quad (3.22)$$

De telle façon que l'on a

$$P\{x_k^{j*} = x_k^i\} = \omega_k^i \quad (3.23)$$

Etant donné que, l'échantillonnage se fait approximativement selon la vraie densité a posteriori, le ré-échantillonnage des poids d'importance suit une distribution uniforme comme dans l'équation (3.21). Comme le ré-échantillonnage se fait pour éviter le problème de dégénérescence alors on peut constituer une nouvelle mesure aléatoire dont le support a des

points avec un poids égale à $1/N$. Plusieurs méthodes ont été proposées pour implémenter la phase de ré-échantillonnage toute en respectant l'expression (3.23). On introduit une variable aléatoire discrète N_k^i qui présente le nombre des fois que x_k^i est sélectionné pendant l'opération de ré-échantillonnage. Sachant que $\{N_k^i\}$ suit la lois multinomiale et $\sum_{i=1}^N N_k^i = N$. Comme, le ré-échantillonnage direct de la fonction de pondération $\{\omega_k^i\}$ va donner $\mathbb{E}\{N_k^i|\omega_k^i\} = N\omega_k^i$ et $\text{var}\{N_k^i|\omega_k^i\} = N\omega_k^i(1 - \omega_k^i)$ pour chaque i . Alors que, de préférence d'utiliser un échantillonnage qui réduise les variances $\{N_k^i|\omega_k^i\}$ comme dans la référence [98]. Cela, empêche la dégénérescence résultant de l'ensemble des états à poids négligeables. Pour implémenter l'étape de ré-échantillonnage, on génère N variables aléatoires indépendantes et identiquement distribuées (i.i.d) suivant la loi uniforme, en suite on fait un tirage croissant de ces variables et les comparer avec la somme cumulé des poids normalisés. Le meilleur algorithme de stockage a une complexité de l'ordre $\mathcal{O}(N \log N)$ ce qui crée une limitation majeure dans les applications pratiques. Cependant, il est possible d'implémenter la procédure de ré-échantillonnage qui a une complexité de l'ordre de $\mathcal{O}(N)$ et minimiser la variance de MC. La table (2-2) présente le pseudo-code de ré-échantillonnage systématique. Notant que $\{c_k^i\}_{i=1}^N$ présente la fonction cumulative de la densité discrète (fcd) correspondant aux poids normalisé, donnée par l'expression suivante :

$$c_k^i = \sum_{j=1}^i \omega_k^j \quad (3.24)$$

Le principe de fonctionnement de l'algorithme de ré-échantillonnage systématique se base sur la génération des valeurs u_i dans l'intervalle $[0,1]$ et à choisir $i^* = \min_j \{j: c_k^j \geq u_i\}$.

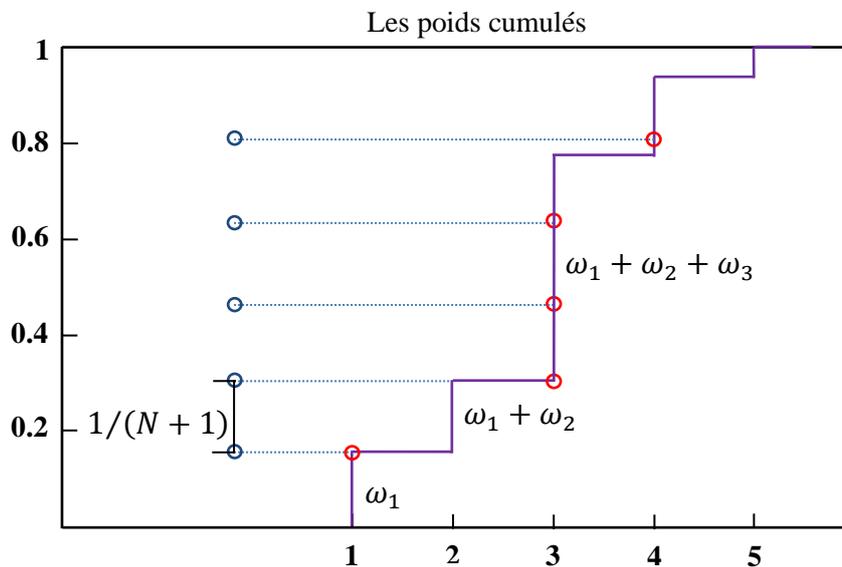


Figure 3-1 Représentation schématique du ré-échantillonnage systématique [99]

Dans cet algorithme du ré-échantillonnage systématique la génération du u_1 est le seul élément aléatoire et les autres points de sélection $\{u_i\}_{i=2}^{N_p}$ sont liés à u_1 de façon déterministe.

Quoique que le ré-échantillonnage empêche la dégénérescence, mais il crée aussi d'autres problèmes : le premier point, le ré-échantillonnage influe sur la forme parallèle de l'algorithme SIS (limite la capacité de paralléliser l'algorithme SIS) car tous les poids ω_k^{i*} doivent être combinés. Deuxièmement, les échantillons x_k^{i*} résultantes de la phase de ré-échantillonnage ne sont pas statistiquement indépendants. Le troisième point est que les particules à poids fort sont choisies pour plusieurs fois. Cette multitude de sélection des particules mène à une perte de diversité car la distribution obtenue inclura de nombreux points répétés. Ce problème est nommé par l'appauvrissement d'échantillonnage et il est hypercritique pour un bruit de processus faible. La table (3-2) présente le pseudo-code de l'algorithme de ré-échantillonnage systématique.

$$[x_k^{j*}, \omega_k^j, i^j]_{j=1}^N = REECHANTILLONNAGE \left[\{x_k^j, \omega_k^j\}_{j=1}^N \right]$$

- Initialiser la fdc (CSW): $c_1 = \omega_k^1$
 - Pour $i = 2 : N$
 - Construire la CSP: $c_i = c_{i-1} + \omega_k^i$
 - Fin pour
 - Commencer du bas de la fdc (CSW) : $i = 1$
 - Générer un point de départ: $u_1 \sim \mathcal{U}[0, N^{-1}]$
 - Pour $j = 1 : N$
 - Se déplacer le long de (CSW): $u_j = u_1 + N^{-1}(j - 1)$
 - TANT QUE $u_j > c_i$
 - $i = i + 1$
 - Fin tant que
 - Assigner un échantillon : $x_k^{j*} = x_k^i$
 - Assigner un poids : $\omega_k^j = N^{-1}$
 - Assigner le parent : $i^j = i$
 - Fin pour
-

Table 3-2 Pseudo-code du ré-échantillonnage systématique

3.6 Filtrage particulaire générique

Dans cette section, on peut introduire une extension de l'algorithme SIS par la mesure de l'indicateur de la dégénérescence et le ré-échantillonnage systématique \hat{N}_{eff} . La table (3-3) présente un pseudo-code de l'algorithme générique qui intègre à la fois l'échantillonnage d'importance et le ré-échantillonnage.

$$\left[\{x_k^i, \omega_k^i\}_{i=1}^N \right] = PF \left[\{x_{k-1}^i, \omega_{k-1}^i\}_{i=1}^N, z_k \right]$$

- Filtrage via SIS (table 3-1) :

$$\left[\{x_k^i, \omega_k^i\}_{i=1}^N \right] = SIS \left[\{x_{k-1}^i, \omega_{k-1}^i\}_{i=1}^N, z_k \right]$$

- Calculer \hat{N}_{eff} en utilisant (3-21)

- Si $\hat{N}_{eff} < N_{th}$

Ré-échantillonnage en utilisant l’algorithme dans la table (3-2)

$$\left[\{x_k^i, \omega_k^i, -\}_{i=1}^N \right] = REECHANTILLONNAGE \left[\{x_{k-1}^i, \omega_{k-1}^i\}_{i=1}^N \right]$$

- Fin Si

Table 3-3 Pseudo-code du filtre particulaire générique

Au cours de la dernière décade cet algorithme et est considéré parmi les filtres les plus populaire et il est connu sous le nom du filtrage particulaire. Le filtre particulaire consiste à approximer la distribution de probabilité $p(x_k | z_{1:k})$ par un grand nombre d’échantillons, dites particules, $\{x_k^i\}_{i=1}^N$, chaque particule représente un état possible du système, et on assigne un poids ω_k^i pour chaque particule. La densité de probabilité dans une région de l’espace d’état est donnée par l’emplacement et le poids d’une particule. Un schéma descriptif d’un filtre particulaire (avec N=10 échantillons), est représenté par la figure (3-2).

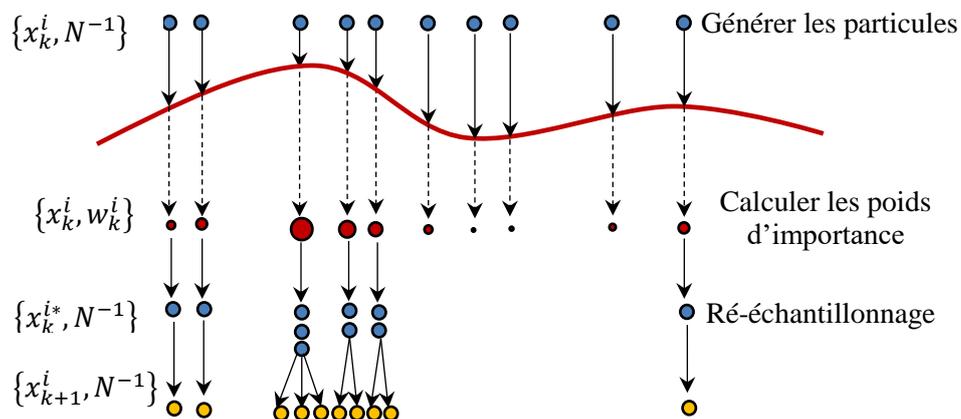


Figure 3-2 Un cycle d’un filtre particulaire

Premièrement le filtre particulaire prendre N échantillons de la distribution initiale. En suite, on génère on génère N particules selon la densité d’importance $q(x_k^i | x_{k-1}^i, z_k)$, Pour déterminer l’emplacement de l’état à l’instant k . La mise à jour des poids d’importance courants se fait selon l’équation (3.18). Dernièrement pour éviter le problème de dégénérescence et la divergence de filtre, l’étape de ré-échantillonnage est nécessaire. Elle consiste à redistribuer les particules de

telle manière qu'on multiplie les particules lourdes pour remplacer les particules de poids faibles.

3.7 Choix de la densité d'importance sous-optimale

Dans le filtrage particulaire le choix de la densité d'importance $q(x_k^i | x_{k-1}^i, z_k)$ est l'un des problèmes les plus cruciaux. L'efficacité de l'algorithme est liée à ce choix. Ainsi que, la génération de particules utilisées dans l'échantillonnage pondéré se fait à partir de la densité d'importance, qui va permettre d'évaluer les poids dans un second temps. Le but de choisir une densité optimale est la minimisation de la variance des poids et atteint les conditions suivantes :

- le support de la densité d'importance doit recouvrir le support de la densité conditionnelle.
- la densité d'importance doit tenir compte de l'observation courante.

La densité optimale est donnée par [95]:

$$q(x_k | x_{k-1}^i, z_k)_{opt} = p(x_k | x_{k-1}^i, z_k) = \frac{p(z_k | x_k, x_{k-1}^i) p(x_k | x_{k-1}^i)}{p(z_k | x_{k-1}^i)} \quad (3.25)$$

En remplaçant (3.25) par (3.17), on aura :

$$\omega_k^i \propto \omega_{k-1}^i p(z_k | x_{k-1}^i) \quad (3.26)$$

Ainsi, pour la densité d'importance optimale, le poids ω_k^i est conditionnellement indépendant du tirage actuel de l'état courant. On peut calculer les poids d'importance avant la propagation de la particule correspondante à l'instant k . Pour utiliser d'importance optimale, il est essentiel de :

- Échantillonner selon $p(x_k | x_{k-1}^i, z_k)$
- Evaluer l'intégrale

$$p(z_k | x_{k-1}^i) = \int p(z_k | x_k) p(x_k | x_{k-1}^i) dx_k \quad (3.27)$$

Il est impossible de faire ce calcul analytiquement. Suivant le même principe de l'algorithme bayésiens récurrents exacts dans le paragraphe (2.5), on peut utiliser la densité optimal dans deux cas [14] : Le premier cas est lorsque l'espace d'état est fini discret. Premièrement, lorsqu'on a un espace d'état fini et discret. Dans ce cas, on peut calculer l'intégrale de la formule (3.27) comme une somme et on peut faire l'échantillonnage à partir de (3.25). Deuxièmement, lorsque le système dynamique est couplé avec un bruit de processus gaussien additif et une équation de mesure linéaire. Dans ce cas, on peut calculer l'intégrale de l'équation (3.27) analytiquement, car ses deux termes sont gaussiens. Par ailleurs, le processus de mesure $p(x_k | x_{k-1}^i, z_k)$ est linéaire et gaussien et admet l'échantillonnage. En général, on ne peut pas faire ces calculs analytiquement pour la densité d'importance optimale.

En parallèles aux solutions optimales, il existe d'autres solutions sous-optimales. Le choix sous-optimal le plus connu est de prendre la densité a priori de transition :

$$q(x_k | x_{k-1}^i, z_k) = p(x_k | x_{k-1}^i) \quad (3.28)$$

Dans ce cas la mesure courante n'est pas prise en compte. En remplaçant (3.28) dans (3.18), on trouve :

$$\omega_k^i \propto \omega_{k-1}^i p(z_k | x_k^i) \quad (3.29)$$

Ce choix rend l'implémentation de l'algorithme simple. Par contre dans le cas d'une densité d'importance optimale, on peut pas calculer le poids ω_k^i avant l'étape de prédiction.

3.8 Versions du filtrage particulaire

La majorité des filtres particulaires développés par les chercheurs sont basés sur L'algorithme d'échantillonnage d'importance séquentiel (SIS). Les différents types sont dérivés de l'algorithme de SIS en jouant sur la modification de l'étape de ré-échantillonnage par un choix judicieux la densité d'importance. Le développement des approximations de la distribution d'importance optimale [100] était le but d'une grande partie des travaux de recherches. Ils existent plusieurs versions de filtres particulaires dans la recherche bibliographique, mais cette section décrit le filtre particulaire SIR, le filtre particulaire auxiliaire ASIR, le filtre particulaire régularisé RPF et le filtre particulaire à modèle multiple MMPF.

3.8.1 Le filtre particulaire SIR (Ré-échantillonnage Séquentiel par Importance des Échantillons)

Le filtrage particulaire a été proposé dans [88] et breveté dans [101]. Les mêmes idée ont été développé par les chercheurs ont donné une nouvelle version de filtrage nommé par "Bootstrap filter"[68] ou filtre du ré-échantillonnage d'importance séquentielle (Sequential Importance Resampling (SIR)). Les hypothèses demandées pour utiliser le filtre de SIR sont très faibles :

- la fonction d'état f et la fonction de mesure h doivent être connues
- il est important de savoir échantillonner selon la distribution du bruit de processus.

En fin, la fonction de vraisemblance $p(z_k | x_k)$ doit être valable pour faire l'évaluation point par point. L'algorithme SIR est obtenu à partir de l'algorithme SIS en choisissant la densité d'importance comme une densité de transition avec l'exécution de l'étape de ré-échantillonnage à chaque instant.

Le choix ci-dessus de la densité de d'importance nécessite des échantillons de la densité $p(x_k | x_{k-1}^i)$. On peut générer les premières échantillons $x_k^i \sim p(x_k | x_{k-1}^i)$ à partir d'un bruit de processus $v_{k-1}^i \sim p_v(v_{k-1})$ et régler $x_k^i = f_{k-1}(x_{k-1}^i, v_{k-1}^i)$ où $p_v(\cdot)$ est la fonction de la densité de probabilité de v_{k-1} . Evidemment, pour ce choix particulier de la densité d'importance, les poids sont donnés par (3.29). Sachant que le ré-échantillonnage est exécuté à chaque instant, et donc $\omega_{k-1}^i = 1 / N$ pour tous $i = 1, \dots, N$. Cela signifie deux choses:

- il n'y a aucune nécessité de passer par les poids d'importance (étant connu) d'un instant un autre instant de l'algorithme ;
- relation (3.29) est simplifiée par :

$$\omega_k^i \propto p(z_k | x_k^j) \quad (3.30)$$

Les poids donnés par (3.32) sont normalisées avant la phase de ré-échantillonnage. Une itération de l'algorithme est ensuite décrite dans la table (3-4).

$$\{x_k^i\}_{i=1}^N = SIR \left[\{x_{k-1}^i\}_{i=1}^N, z_k \right]$$

- Pour $i = 1:N$
 - Prédiction : Générer $x_k^i \sim p(x_k | x_{k-1}^i)$
 - Correction : Calculer $\tilde{\omega}_k^i \sim p(z_k | x_k^i)$
- Fin pour
- Calculer les poids total : $t = SUM \left[\{\tilde{\omega}_k^i\}_{i=1}^N \right]$
- Pour $i = 1:N$
 - Normalisation : $\tilde{\omega}_k^i = t^{-1} \tilde{\omega}_k^i$
- Fin pour
- Ré-échantillonnage en utilisant la table (3-2) :

$$\left[\{x_k^i, -, -\}_{i=1}^N \right] = REECHANTILLONNAGE \left[\{x_k^i, \omega_k^i\}_{i=1}^N \right]$$

Table 3-4 Pseudo-code du filtre particulière SIR

Comme la densité d'importance d'échantillonnage pour le filtre SIR est indépendante de la mesure z_k , l'espace d'état est explorée sans aucune connaissance des observations (sans connaître des mesure). Par conséquent, ce filtre peut être inefficace et sensible aux valeurs aberrantes. En outre, comme le ré-échantillonnage est appliquée à chaque itération, cela peut conduire à une perte rapide de la diversité dans les particules. Cependant, la méthode SIR, présente l'avantage que les poids d'importance sont évalués facilement et la densité d'importance peut être facilement échantillonnée.

3.8.2 Filtre particulière auxiliaire (ASIR)

Le filtre SIR auxiliaire (ASIR) a été présenté par Pitt et Shephard [102] comme une variante de SIR standard. L'idée de base est d'effectuer l'étape de ré-échantillonnage à l'instant $k - 1$ (en utilisant la mesure disponible au moment k), avant que les particules sont propagées à l'instant k . De cette manière, le filtre à ASIR tente d'imiter la séquence d'étapes effectuées lorsque la densité d'importance optimal est disponible. La dérivation de filtre ASIR découle le cadre SIS en introduisant un $q(x_k, i | z_k)$ de densité de l'importance, ce qui échantillons de la paire $\{x_k^j, i^j\}_{j=1}^N$, où je réfère à l'indice des particules à $k - 1$.

En appliquant la règle de Bayes, proportionnalité peut être dérivée $p(x_k, i | z_k)$ comme:

$$\begin{aligned} p(x_k, i | z_{1:k}) &\propto p(z_k | x_k) p(x_k, i | z_{1:k-1}) = p(z_k | x_k) p(x_k | i, z_{1:k-1}) p(i | z_{1:k-1}) \\ &= p(z_k | x_k) p(x_k | x_{k-1}^j) \omega_{k-1}^i \end{aligned} \quad (3.31)$$

Le filtre de ASIR fonctionne par obtention d'un échantillon à partir de la densité de joint $p(x_k, i | z_{1:k})$, puis en omettant l'indice i dans la paire (x_k, i) pour produire un échantillon $\{x_j^j\}_{j=1}^N$ de la densité $p(x_k | z_{1:k})$ marginaux. La densité de l'importance utilisée pour tirer l'échantillon $\{x_k^j, i^j\}_{j=1}^N$ est défini pour satisfaire la proportionnalité

$$q(x_k, i | z_{1:k}) \propto p(z_k | \mu_k^i) p(x_k | x_{k-1}^i) \omega_{k-1}^i \quad (3.32)$$

Où μ_k^i est certaine caractérisation de x_k est donnée x_{k-1}^i . Cet pourrait être le moyen, dans ce cas, $\mu_k^i = \mathbb{E}[x_k | x_{k-1}^i]$ ou un échantillon écrit $\mu_k^i \sim p(x_k | x_{k-1}^i)$. Par

$$q(x_k, i | z_{1:k}) = q(i | z_{1:k}) q(x_k | i, z_{1:k}) \quad (3.33)$$

et définissant

$$q(x_k | i, z_{1:k}) \triangleq p(x_k | x_{k-1}^i) \quad (3.34)$$

Il résulte de (3.32) qui

$$q(i | z_{1:k}) \propto p(z_k | \mu_k^i) \omega_{k-1}^i \quad (3.35)$$

Selon (3.18), l'échantillon $\{x_k^j, i^j\}_{j=1}^N$ est alors attribué un poids proportionnel au rapport de la droite de (3.31) et (3.32) :

$$\omega_k^j \propto \omega_{k-1}^j \frac{p(z_k | x_k^j) p(x_k^j | x_{k-1}^{i^j})}{q(x_k^j, i^j | z_{1:k})} = \frac{p(z_k | x_k^j)}{q(z_k | \mu_k^{i^j})} \quad (3.36)$$

Une description de pseudo code d'un seul cycle du filtre de ASIR est présenté dans la table (3-5). Le filtre de ASIR originale comme proposé dans [102] comprenait une étape de ré-échantillonnage supplémentaire à la fin de chaque cycle pour produire un ensemble tout aussi pondéré de particules. Cette étape de ré-échantillonnage supplémentaire est montrée qu'elle est inutile [103] elle est supprimé dans le table (3-5).

$$\left[\{x_k^i, \omega_k^i\}_{i=1}^N \right] = ASIR \left[\{x_{k-1}^i, \omega_{k-1}^i\}_{i=1}^N, z_k \right]$$

- Pour $i = 1:N$

Calculer μ_k^i

Calculer $\tilde{\omega}_k^i = q(i|z_{1:k}) \propto p(z_k | \mu_k^i) \omega_{k-1}^i$

- Fin pour

- Calculer les poids total: $t = SUM \left[\{\tilde{\omega}_k^i\}_{i=1}^N \right]$

- Pour $i = 1:N$

Normalisation : $\omega_k^i = t^{-1} \tilde{\omega}_k^i$

- Fin Pour

- Ré-échantillonnage en utilisant l'algorithme de la table (3-2) :

$$\left[\{-, -, i^j\}_{i=1}^N \right] = REECHANTILLONNAGE \left[\{\mu_k^i, \omega_k^i\}_{i=1}^N \right]$$

- Pour $i = 1:N$

Générer $x_k^j \sim q(x_k | i^j, z_{1:k}) = p(x_k | x_{k-1}^{i^j})$, comme dans le filtre SIR

Assigner le poids $\tilde{\omega}_k^i$ en utilisant (3.36)

- Fin pour

- Calculer la somme total des poids : $t = SOMME \left[\{\tilde{\omega}_k^i\}_{i=1}^N \right]$

- For $i = N$

Normaliser : $\omega_k^i = t^{-1} \tilde{\omega}_k^i$

- End for

Table 3-5 Pseudo-code de filtre particulaire auxiliaire

3.8.3 Le filtre particulaire régularisé (RPF)

On a vu que le ré-échantillonnage classique appauvrissait dans certains cas le système de particules dans la mesure où les schémas de redistribution sont fondées sur la duplication de particules. En particulier lorsque le bruit de dynamique est faible, les particules explorent peu l'espace d'état et le filtre peut diverger. Afin d'éviter ceci, le filtre particulaire régularisé (RPF) [89][104], effectue le ré-échantillonnage en simulant un échantillon selon une distribution continue, ce qui évite d'avoir plusieurs copies d'une même particule. La distribution continue utilisée est obtenue en régularisant la densité discrète $p(x_k | z_{1:k}) \approx \sum_{i=1}^N \omega_k^i \delta(x_k - x_k^i)$ obtenue après l'étape de correction. Précisément, dans le RPF, les échantillons sont tirés de l'approximation.

$$p(x_k | z_k) \approx \sum_{i=1}^N \omega_k^i K_h(x_k - x_k^i) \quad (3.37)$$

Pour tout $h > 0$ et tout $\mathbf{x} \in \mathbb{R}^d$, on définit le noyau de régularisation

$$K_h(\mathbf{x}) = \frac{1}{h^{n_x}} K\left(\frac{\mathbf{x}}{h}\right) \quad (3.38)$$

Le paramètre h s'appelle facteur de dilatation, n_x est la dimension du vecteur d'état \mathbf{x} , ω_k^i sont des poids normalisés, le noyau de régularisation est une fonction de densité de probabilité symétrique telle que

$$\int \mathbf{x}K(\mathbf{x})d\mathbf{x} = 0, \quad \int \|\mathbf{x}\|^2 K(\mathbf{x})d\mathbf{x} < \infty \quad (3.39)$$

En estimation de densité par noyaux, le noyau de régularisation $K(\cdot)$ et facteur de dilatation h sont choisis de manière à minimiser l'erreur quadratique intégrée moyenne (MISE) entre la densité à posteriori réelle et la représentation empirique régularisée correspondante dans (3.37), qui est définie comme suit

$$MISE(\hat{p}) = \mathbb{E}[\int [\hat{p}(\mathbf{x}_k | \mathbf{z}_k) - p(\mathbf{x}_k | \mathbf{z}_k)]^2 d\mathbf{x}_k] \quad (3.40)$$

En particulier, lorsque $\omega = \frac{1}{N}$ pour $i = 1, \dots, N$, le noyau optimal K_{opt} est le noyau d'Epanechnikov défini par [105]:

$$K_{opt} = \begin{cases} \frac{n_x+2}{n_x} & \text{si } \|\mathbf{x}\| < 1 \\ 0 & \text{sinon} \end{cases} \quad (3.41)$$

Si p est une densité gaussienne standard, en utilisant le noyau d'Epanechnikov (3.41)

$$h_{opt} = A \cdot N^{-\frac{1}{n_x+4}} \quad \text{avec} \quad A = \left[8c_{n_x}^{-1}(n_x + 4)(2\sqrt{\pi})^{n_x} \right]^{\frac{1}{n_x+4}} \quad (3.42)$$

où c_{n_x} est le volume de la sphère unité. Pour les applications usuelles, il est suffisant d'utiliser un noyau gaussien, dont le coût de simulation est moindre. Dans ce cas, h_{opt} est obtenu selon

$$h_{opt} = A \cdot N^{-\frac{1}{n_x+4}} \quad \text{avec} \quad A = \left[\frac{4}{(n_x+4)} \right]^{\frac{1}{n_x+4}} \quad (3.43)$$

Un cycle de filtre particulaire régularisée est donné un algorithme dans la table (3-6). Le filtre particulaire régularisé ne diffère du filtre particulaire générique (table 3-3) que par les étapes de régularisation supplémentaires lors du ré-échantillonnage. Notez également que le calcul de la matrice de covariance empirique S_k est effectué avant le ré-échantillonnage et est donc fonction à la fois de la valeur \mathbf{x}_k^i et de la valeur ω_k^i . L'étape clé est la suivante

$$\mathbf{x}_k^{i*} = \mathbf{x}_k^i + h_{opt} D_{k\epsilon^i} \quad (3.44)$$

L'inconvénient théorique du FPR est que ses échantillons ne sont plus garantis pour se rapprocher asymptotiquement de ceux de la partie à posteriori.

$$\left[\{x_k^{i*}, \omega_k^i\}_{i=1}^N \right] = RPF \left[\{x_{k-1}^i, \omega_{k-1}^i\}_{i=1}^N, z_k \right]$$

- Pour $i = 1:N$

Générer $x_k^j \sim p(x_k | x_{k-1}^j)$

Calculer $\tilde{\omega}_k^i = p(z_k | x_k^i)$

- Fin pour

- Calculer la somme total des poids : $t = \text{SOMME} \left[\{\tilde{\omega}_k^i\}_{i=1}^N \right]$

- Pour $i = 1:N$

Normaliser : $\omega_k^i = t^{-1} \tilde{\omega}_k^i$

- Fin pour

- Calculer \hat{N}_{eff} en utilisant (3.20)

- Si $\hat{N}_{eff} < N_{th}$

Calculer la matrice de covariance empirique S_k de $\{x_k^i, \omega_k^i\}_{i=1}^N$

Calculer D_k de telle sorte que $D_k D_k^T = S_k$

Ré-échantillonnage en utilisant l'algorithme de la table (3-2)

$$\left[\{x_k^i, \omega_k^i, -\}_{i=1}^N \right] = REECHANTILLONNAGE \left[\{x_k^i, \omega_k^i\}_{i=1}^N \right]$$

Pour $i = 1:N$

Générer $\epsilon^i \sim K$ suivant le noyau d'Epanechnikov ou un noyau gaussien

$$x_k^{i*} = x_k^i + h_{opt} D_{k\epsilon^i}$$

End for

- End if

Table 3-6 Pseudo-code de filtre particulaire régularisé RPF

Les applications du RPF dans le domaine de la poursuite de cible ont montré que la régularisation améliore sensiblement les performances du filtre particulaire classique (SIR) notamment en termes de taux de non-divergence, lorsque la dynamique est faiblement bruitée.

3.8.4 Filtre particulaire à modèle multiple (MMPF)

Le filtre particulaire à modèle multiples (MM) a été proposé par plusieurs auteurs [104][106][107] pour effectuer un filtrage non linéaire par commutation des modèles dynamiques. Le problème appartient à une classe plus large aux problèmes hybrides de l'estimation d'état où le vecteur d'état (augmentée) comprend à la fois une partie à valeur continue (continuous-valued) et une partie à valeur discret (discrete-valued). Les composantes du vecteur à valeur continue (continu-évaluées) sont généralement les variables cinématiques des cibles (position, vitesse, etc.) et peut être des paramètres inconnus (par exemple, coefficient

balistique dans chapiteau 5). Le vecteur à valeur dicrète (discrete-valued) peut être une combinaison de:

- Le régime variable r_k , qui détermine quel modèle dynamique est en vigueur du t_{k-1}^+ à t_k
- Les caractéristique non-cinématique de la cible (de classe, l'allégeance), utilisés dans les cibles communes et la classification des problèmes [108].
- Le vecteur de l'association de données, qui détermine l'origine des mesures en présence de bruit 'clutter' et / ou des cibles multiples [109].

Le filtre MMPF est une approximation séquentiel Monte Carlo de la solution conceptuelle donnée par ('prédiction') et ('correction'). On a le vecteur d'état augmenté est défini comme $y_k = [x_k^T \ r_k]^T$ où $r_k \in S = \{1, 2, \dots, s\}$ est en conformité avec les définitions et les notations de la section 1.4. Supposant Les densités initiales $p(x_0)$ et $p(r_1) = \sum_{i=1}^s \mu_i \delta(r_1 - i)$ connus. en outre, soit $\{y_k^n, \omega_k^n\}_{n=1}^N$ représente une mesure aléatoire caractérisé par la densité a posteriori $p(y_k | Z_k)$, de telle sorte que chaque particule y_k^n est constitué de deux composants: x_k^n et r_k^n . Un pseudo-code général d'un filtre à particules à MM (MMPF) est présenté dans la table (3-7).

La première étape de cet algorithme est de générer un ensemble aléatoire $\{r_k^n\}_{n=1}^N$ basé sur $\{r_{k-1}^n\}_{n=1}^N$ et la matrice du transition $\Pi = [\pi_{ij}]$, où $i, j \in S$. Cela peut être fait en utilisant un algorithme montré dans la table (A-1), dont la mise en œuvre est la suivante: si $r_{k-1}^n = i$ et $u_n \sim \mathcal{U}[0,1]$, alors $r_k^n = i$ est fixé à $m \in S$ tel que:

$$\sum_{j=1}^{m-1} \pi_{ij} < u_n < \sum_{j=1}^m \pi_{ij} \quad (3.45)$$

$$[\{y_k^n, \omega_k^n\}_{n=1}^N] = MMPF[\{y_{k-1}^n, \omega_{k-1}^n\}_{n=1}^N, z_k]$$

- Régime de transitoire (Table A-1)
- Régime conditionné SIS (Table A-2)
- Calculer \hat{N}_{eff} utilisant (3.20)
- SI $\hat{N}_{eff} < N_{thr}$

Ré-échantillonnage utilisant la table (3-2) :

- $[\{y_k^n, \omega_k^n, -\}_{n=1}^N] = REECHANTILLONNAGE[\{y_k^n, \omega_k^n\}_{n=1}^N]$
 - FIN SI
-

Table 3-7 Pseudo-code de filtre particulaire générique à modèle multiple MMPF

La $sum \sum_{j=1}^m \pi_{ij}$ présente la fonction de répartition du variable aléatoire discrète r_k donné $r_{k-1} = i$.

L'étape suivante de filtre MMPF générique effectue un filtrage SIS à régime conditionné, décrit dans la table (A-2). La densité d'importance optimale de régime conditionné est donnée par:

$$q(x_k | x_{k-1}^n, r_k^n, z_k)_{opt} = p(x_k | x_{k-1}^n, r_k^n, z_k) \quad (3.46)$$

Bien que le choix le plus utilisé[105][106][107]semble être transitoire à priori

$$q(\mathbf{x}_k | \mathbf{x}_{k-1}^n, r_k^n, z_k) = p(\mathbf{x}_k | \mathbf{x}_{k-1}^n, r_k^n) \quad (3.47)$$

3.9 Conclusion

Ce chapitre décrit les techniques de filtrage particulaire. Nous avons commencé par les deux étapes clés d'un filtre particulaire générique qui sont : (1) l'échantillonnage séquentiel d'importance et (2) le ré-échantillonnage. Le choix d'une bonne densité d'importance a été souligné et certaines solutions possibles ont été examinées. Enfin, le chapitre a présenté les différentes versions relativement répondues de filtres particulaires, appuyées par leur pseudo-code pour en faciliter la mise en œuvre. Cependant, La classe des filtres particulaires est beaucoup plus large, et de nombreuses autres variations. Enfin, le filtre particulaire sera utilisé dans l'approche track-before-detecte dans le chapitre suivant pour détecter et suivre simultanément une seule cible.

4. L'APPROCHE TRACK-BEFORE-DETECT MONO-CIBLE

4. L'APPROCHE TRACK-BEFORE-DETECT MONO-CIBLE	78
4.1 Introduction	79
4.2 L'approche TBD mono-cible	80
4.2.1 Le modèle d'état	80
4.2.2 La matrice de transition	80
4.2.3 Le modèle de mesures	81
4.2.3.1 Modèle de mesures image	81
4.2.3.2 Modèle de mesures radar	82
4.2.4 La solution bayésienne de filtrage Track Before Detect	83
4.2.4.1 Prédiction	84
4.2.4.2 Mise à jour (Correction)	84
4.2.4.1 La fonction de vraisemblance pour les mesures images	85
4.2.4.2 La fonction de vraisemblance pour les mesures radar	85
4.2.5 Implémentation de filtre particulaire	87
4.1 Simulations et commentaires de l'algorithme PF-TBD (Les mesures Images)	89
4.1.1 Cible non-manouvrante	89
4.1.1.1 Scénario 1 (Modèle CV)	89
4.1.2 Cible manouvrantes	92
4.1.2.1 Scénario 1 (Modèle CT)	92
4.1.2.1 Scénario 2 (Modèle CA)	94
4.2 Simulations et commentaires de l'algorithme PF-TBD (les mesures Radar)	96
4.2.1 Cible manouvrantes	97
4.2.1.1 Scénario 1 (Modèle CT)	97
4.2.1.2 Scénario 2 (Modèle CA)	100
4.3 Conclusion	102

Ce chapitre présente l'approche Track-Before-Detect mono-cible utilisant le filtrage particulaire pour deux types des données mesures (mesures Image et mesure Radar) et trois modèles de trajectoires de la cible (CV, CT, CA). Et nous présentons les résultats et les commentaires de simulation de l'algorithme FP-TBD.

4.1 Introduction

L'approche conventionnelle de la poursuite de cible est basée sur les mesures de plusieurs paramètres d'une cible (la position, la vitesse, ...) qui sont extraits par le seuillage de la sortie d'une unité de traitement de signal d'un capteur de surveillance [16]. Le rôle principal du seuillage est de réduire le flux de données et de simplifier la poursuite. Pour une cible d'un certain rapport signal sur bruit (SNR), le choix du seuil de détection est basé sur la probabilité de détection de la cible et la densité de fausses alarmes. D'autre part, le taux de fausse alarme influe sur la complexité du problème d'association de données dans le système de poursuite. En général, les densités élevées de fausses alarmes nécessitent des algorithmes d'association de données plus complexes.

Cependant, l'effet indésirable de seuillage des données d'un capteur fait perdre des informations utiles du fait de la limitation du flux de données. Pour les cibles de SNR élevés, cette perte d'information est peu inquiétante, car on peut obtenir une bonne probabilité de détection avec un faible taux de fausse alarme. Les développements récents des avions militaires furtifs et des missiles de croisière ont montré le caractère important de la détection et la poursuite des cibles à faible RSB. Pour ces cibles, il est avantageux d'utiliser les données non-seuillées (sans seuil) pour la détection et la poursuite de piste simultanément [75][81]. Selon le type de capteur utilisé, les données non-seuillées peuvent être des séquences d'images distance-doppler (pour un radar), les distributions portant fréquence (pour un sonar passif), ou gray-scale images (des images gris) (pour le démarrage TV ou une caméra infrarouge).

Le concept de détection et de poursuite simultanée utilisant les données non-seuillées est connu dans la littérature comme l'approche Track-Before-Detect (TBD). Typiquement, le TBD est implémenté comme un algorithme de traitement par lots (batch algorithm) en utilisant : la transformée de Hough [79], la programmation dynamique [75][81], l'estimation du maximum de vraisemblance [41]. Ces méthodes fonctionnent sur plusieurs lots de données, elles permettent d'interdire ou de pénaliser les écarts par rapport à un mouvement rectiligne et en général exigent d'énormes ressources de calcul.

Dans ce chapitre, nous développons un estimateur bayésien récursif TBD. Cependant, la formulation et l'implémentation sont basées sur le filtre particulaire. Le concept de base suit l'approche présentée par Salmond et al [42][110]. Les avantages de l'approche bayésienne récursive TBD proposée sont multiples :

- On n'a pas besoin de stocker et de traiter plusieurs balayages (scans) de données ;
- Le mouvement de la cible est modélisé par une équation dynamique stochastique (donc la méthode n'est pas limitée au mouvement linéaire) ;
- L'approche est valable pour un milieu bruité structuré et non gaussien ;
- Les effets inconnus et fluctuants de l'intensité de la cible (ou SNR), les fonctions de propagation ponctuelles et les objets étendus sont adaptés ;
- La présence et l'absence de la cible (en raison d'occlusions par exemple) sont explicitement modélisées.

Premièrement, le capteur est supposé produire une séquence des données mesures (frames) caractérisée par la résolution finie (par exemple, la cible possède une taille de sous-pixel). Souvent, la résolution limitée du capteur est ignorée par les scientifique, ce qui constitue un problème pratique important pour la poursuite de cible [111]. Deuxièmement, l'existence de la cible est introduit afin de détecter des cibles et d'initialiser des pistes. Ce concept, introduit dans [112][113], nous permet de calculer la probabilité de l'existence de la cible directement à partir du filtre.

Ce chapitre est organisé de la manière suivante : La formulation de problème est présentée le premier paragraphe, en donnant le modèle d'état de cible et les modèles de mesures (images et radar). Tandis que le paragraphe après détaille l'approche TBD comme un problème de filtrage non linéaire et décrit en même temps la solution bayésienne récursive. Ensuite, nous présentons L'implémentation de cette solution utilisant le filtre particulière pour les deux cas de mesures. Enfin, nous présentons en les résultats de simulations et commentaires pour différent modèles de trajectoires.

4.2 L'approche TBD mono-cible

4.2.1 Le modèle d'état

On considère une cible d'un certain niveau d'intensité (luminosité) se déplaçant dans le plan x - y selon un modèle dynamique à temps discret connu de la forme :

$$\mathbf{x}_{k+1} = f_k(\mathbf{x}_k, \mathbf{v}_k) \quad (4.1)$$

Où k est l'indice en temps discret, \mathbf{v}_k est la séquence de processus de bruit et \mathbf{x}_k est le vecteur d'état défini comme :

$$\mathbf{x}_k = [x_k \quad \dot{x}_k \quad y_k \quad \dot{y}_k \quad I_k]^T \quad (4.2)$$

Où $\mathbf{x}_k = (x, y), (\dot{x}, \dot{y})$ et I_k désigne la position, la vitesse et l'intensité de la cible, respectivement. La spécification de l'équation (4.1) est équivalente à la connaissance de la densité de transition $p(\mathbf{x}_{k+1}|\mathbf{x}_k)$.

4.2.2 La matrice de transition

La cible peut être présente ou absente dans la zone de surveillance (ou le champ de vision) à un instant discret k . La variable E_k de La présence de la cible (l'existence) est modélisée par une chaîne de Markov à deux états, c.à.d $E_k \in \{0,1\}$. Ici, 0 désigne le cas où la cible n'est pas présente (cible absente), alors que 1 désigne le cas contraire (cible présente) [112][113]. En outre, nous supposons que les probabilités de transition de la cible «naissante» "birth" (P_b) et «morte» "death" (P_d), sont définies comme suit :

$$P_d \triangleq P\{E_k = 1 | E_{k-1} = 0\} \quad (4.3)$$

$$P_d \triangleq P\{E_k = 0 | E_{k-1} = 1\} \quad (4.4)$$

Les deux autres probabilités de transition de cette chaîne de Markov sont la probabilité de rester en vie et la probabilité de rester absent, respectivement sont données par :

$$1 - P_b \triangleq P\{E_k = 0 | E_{k-1} = 0\} \quad (4.5)$$

$$1 - P_d \triangleq P\{E_k = 1 | E_{k-1} = 1\} \quad (4.6)$$

En résumé la matrice de probabilité de transition (TPM) est donnée par :

$$\Pi = \begin{bmatrix} 1 - P_b & P_b \\ P_d & 1 - P_d \end{bmatrix} \quad (4.7)$$

La probabilité d'existence initiale d'une cible (à l'instant $k = 1$), est notée par $\mu_1 = P\{E_1 = 1\}$ est également supposée connue.

4.2.3 Le modèle de mesures

4.2.3.1 Modèle de mesures image

Le capteur fournit une séquence d'images bidimensionnelles (des frames) de la région de surveillance. Chaque image comprend $(n \times m)$ cellules de résolution (pixels). Une cellule de résolution correspond à une zone rectangulaire de dimensions $\Delta_x \times \Delta_y$ de sorte que le centre de chaque cellule (i, j) est défini comme étant à $(i\Delta_x \times j\Delta_y)$ pour $i = 1, \dots, n$ et $j = 1, \dots, m$.

Les images mesurées sont enregistrées à des instants discrets k avec un intervalle d'échantillonnage T . La figure (4-1) montre un exemple des mesures dans différents frame d'une cible qui se déplace dans plan de 2D.

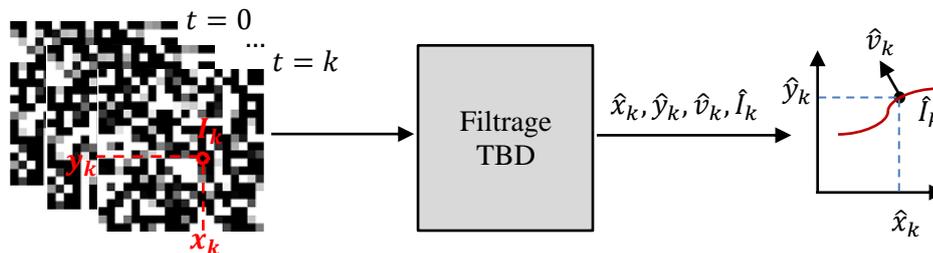


Figure 4-1 Une cible se déplace dans un plan de 2-D

A chaque cellule de résolution (i, j) , l'intensité mesurée est désignée par $z_k^{(i,j)}$ est modélisée comme:

$$z_k^{(i,j)} = \begin{cases} h_k^{(i,j)}(\mathbf{x}_k) + \omega_k^{(i,j)} & \text{si la cible est presente} \\ \omega_k^{(i,j)} & \text{si la cible est absente} \end{cases} \quad (4.8)$$

Où $h_k^{(i,j)}(\mathbf{x}_k)$ est la contribution de la cible au niveau d'intensité dans la cellule de résolution (i, j) et $\omega_k^{(i,j)}$ est le bruit de mesure dans la cellule de résolution (i, j) , supposé indépendant de pixel à pixel et de frame au frame. Pour simplifier, on suppose du bruit de fond (background noise) gaussien et homogène ; c'est-à-dire suit la loi normale $\omega_k^{(i,j)} \sim \mathcal{N}(\omega; 0, \sigma^2)$. Cependant, nous soulignons, que la solution bayésienne récursive qui sera présentée par la suite est applicable même au bruit de mesure non-homogène et non-gaussien, aussi longtemps que les statistiques de $\omega_k^{(i,j)}$ sont connues pour chaque cellule (i, j) .

La contribution de l'intensité de la cible $h_k^{(i,j)}(x_k)$, due à la mesure de la cible (pour les grandes cibles) ou à la fonction de point d'étalement du capteur. Nous nous concentrons sur ce dernier ; en particulier, nous considérons une cible ponctuelle et la fonction point d'étalement de capteur approximée par une densité gaussienne à deux dimensions avec une symétrie circulaire. Ainsi pour une cible ponctuelle d'intensité I_k à la position (x_k, y_k) , la contribution au pixel (i, j) est approximée par :

$$h_k^{(i,j)}(x_k) \approx \frac{\Delta_x \Delta_y I_k}{2\pi\Sigma^2} \exp\left\{-\frac{(i\Delta_x - x_k)^2 + (j\Delta_y - y_k)^2}{2\Sigma^2}\right\} \quad (4.9)$$

Où Σ est un paramètre connu qui représente la quantité de flou (ambiguïté) introduit par le capteur. L'expression (4.9) se rapproche l'intégrale de la fonction de point d'étalement sur la cellule de résolution et l'intervalle d'échantillonnage [41].

Les mesures complètes enregistrées à l'instant k sont une matrice $n \times m$ donnée par :

$$z_k = \{z_k^{(i,j)} : i = 1, \dots, n, j = 1, \dots, m\} \quad (4.10)$$

Alors que l'ensemble des mesures complètes recueillies jusqu'à l'instant k est noté comme suite : $z_{1:k} = \{z_i, i = 1, \dots, k\}$.

4.2.3.2 Modèle de mesures radar

Dans le filtrage particulaire, nous utilisons les mesures non-seuillée. Nous supposons un prétraitement des données de mesures radar pour différentes portée r_k , vitesse radiale \dot{r}_k et angle azimutal ϕ_k . La fonction d'ambiguïté croisée entre le signal émis et le signal radar reçu est considérée comme un exemple de fonction de mesure.

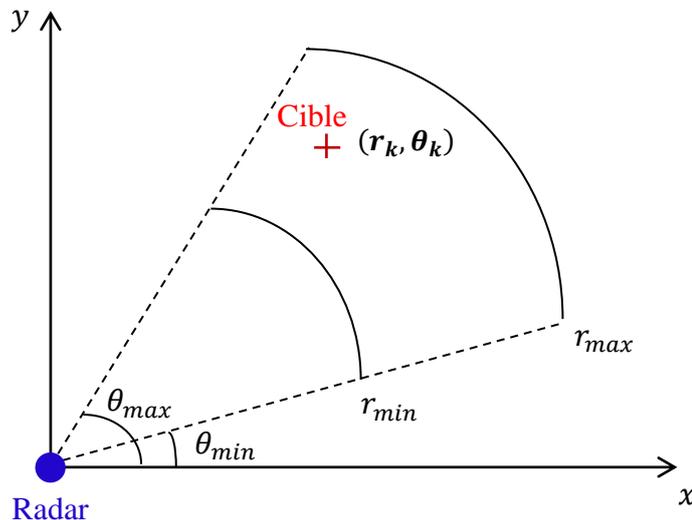


Figure 4-2 une cible radar avec des mesures en coordonnées polaires

Les différents paramètres radar associés au vecteur d'état comme la portée, la vitesse radiale et l'angle azimutal est données par :

$$\begin{aligned}
r_k &= \sqrt{(x_k - x_0)^2 + (y_k - y_0)^2} \\
\dot{r}_k &= \frac{\dot{x}_k(x_k - x_0) + \dot{y}_k(y_k - y_0)}{\sqrt{(x_k - x_0)^2 + (y_k - y_0)^2}} \\
\theta_k &= \arctan\left(\frac{y_k - y_0}{x_k - x_0}\right)
\end{aligned} \tag{4.11}$$

et (x_0, y_0) est la position 2D du radar.

Nous supposons qu'un modèle de cible ponctuelle et une fonction d'étalement ponctuel du radar peuvent être approximés par une fonction gaussienne 3-D. Selon cette hypothèse, la mesure combinée $z_k^{(i,j,\ell)}$ à la the (i, j, ℓ) ième bin est donnée comme :

$$z_k^{(i,j,\ell)} = \begin{cases} \Psi_k^{(i,j,\ell)}(\mathbf{x}_k) + \omega_k^{(i,j,\ell)} & \text{if } m_k = 1 \\ \omega_k^{(i,j,\ell)} & \text{if } m_k = 0 \end{cases} \tag{4.12}$$

avec

$$\Psi_k^{(i,j,\ell)}(\mathbf{x}_k) \approx \frac{\Delta_r \Delta_{\dot{r}} \Delta_\theta}{(2\pi)^{3/2} \sigma_r \sigma_{\dot{r}} \sigma_\theta} \exp\left\{-\left(\frac{i\Delta_r - r_k}{2\sigma_r}\right)^2 - \left(\frac{j\Delta_{\dot{r}} - \dot{r}_k}{2\sigma_{\dot{r}}}\right)^2 - \left(\frac{\ell\Delta_\theta - \theta_k}{2\sigma_\theta}\right)^2\right\} \tag{4.13}$$

Le radar fournit une série de frames de la zone de surveillance ; chaque frame est composée de $(N_r \times N_{\dot{r}} \times N_\theta)$ représentant la portée, la vitesse radiale et l'angle azimutal. Une cellule de résolution relie une zone 3-D de dimensions $\Delta_r \times \Delta_{\dot{r}} \times \Delta_\theta$ afin que le centre de chaque cellule (i, j, ℓ) soit déterminé à $(i\Delta_r \times j\Delta_{\dot{r}} \times \ell\Delta_\theta)$ pour $i = 1, \dots, N_x, j = 1, \dots, N_y$ et $\theta = 1, \dots, N_\theta$, le signal reçu de la cible a une intensité I_k , et $\sigma_r, \sigma_{\dot{r}}$ et σ_θ sont les paramètres de contrôle de la propagation causée par le système radar supposé connu. Notez que $\sigma_r, \sigma_{\dot{r}}$ sont définis par la fonction d'ambiguïté du signal émit radar [114] [49] et σ_θ est défini par la l'ouverture du faisceau de l'antenne.

Le bruit de mesure $\omega_k^{(i,j,\ell)}$ dans (4.12) est supposé gaussien avec une moyenne zéro et une variance v_k dans la cellule de résolution (i, j, ℓ) . La frame surveillée sera enregistrée à l'instant discret k avec l'intervalle d'échantillonnage T .

Les mesures finales sont enregistrées au temps k et données par :

$$z_k = \left\{ z_k^{(i,j,\ell)} : i = 1, \dots, n, j = 1, \dots, m \right\} \tag{4.14}$$

Alors que l'ensemble des mesures complètes recueillies jusqu'à l'instant k est noté comme suit :

$$z_{1:k} = \{z_i, i = 1, \dots, k\} \tag{4.15}$$

4.2.4 La solution bayésienne de filtrage Track Before Detect

On peut formuler Le problème TBD sous l'estimation bayésienne récursive. On a la fonction de densité de probabilité (pdf) conjointe à postériori de l'état et de l'existence de la cible à l'instant $k - 1$, notée par $p(\mathbf{x}_{k-1}, E_{k-1} | z_{1:k-1})$, ainsi que la dernière image (frame) disponible z_k , l'objectif est de construire la partie à postériori de la fonction densité de probabilité conjointe à l'instant k , $p(\mathbf{x}_k, E_k | z_{1:k})$. La probabilité à posteriori de l'existence de la cible à l'instant k est donnée par

$$P_k \triangleq P\{E_k = 1|z_{1:k}\} \quad (4.16)$$

ensuite elle est calculée comme une marginal de $p(x_k, E_k = 1|z_{1:k})$. Le problème est conceptuellement une estimation hybride décrite dans le chapitre 2 (paragraphe 2.6). Cependant, cette fois, la valeur de la variable discrète est différente : au lieu du régime r_k , nous traitons avec l'existence de la cible E_k .

Comme expliqué dans les références [15] et [115], la solution formelle bayésienne récursive peut être présentée comme une procédure en deux étapes: *la prédiction et la mise à jour(Correction)*.

4.2.4.1 Prédiction

L'état cible n'est pas défini lorsque la cible est absente ($E_k = 0$). Par conséquent, en supposant que la cible est présente ($E_k = 1$), La densité de la prédiction peut s'exprimer par rapport à l'état et la variable d'existence de la cible à l'instant précédent, comme suit :

$$\begin{aligned} p(x_k, E_k = 1|z_{1:k-1}) = \\ \int p(x_k, E_k = 1|x_{k-1}, E_{k-1} = 1, z_{1:k-1})p(x_{k-1}, E_{k-1} = 1|z_{1:k-1})dx_{k-1} \\ + \int p(x_k, E_k = 1|x_{k-1}, E_{k-1} = 0, z_{1:k-1})p(x_{k-1}, E_{k-1} = 0|z_{1:k-1})dx_{k-1} \end{aligned} \quad (4.17)$$

Où

$$\begin{aligned} p(x_k, E_k = 1|x_{k-1}, E_{k-1} = 1, z_{1:k-1}) = p(x_k|x_{k-1}, E_k = 1, E_{k-1} = 1)P\{E_k = 1|E_{k-1} = 1\} \\ = p(x_k|x_{k-1}, E_k = 1, E_{k-1} = 1)(1 - P_d) \end{aligned} \quad (4.18)$$

Et

$$\begin{aligned} p(x_k, E_k = 1|x_{k-1}, E_{k-1} = 0, z_{1:k-1}) = p(x_k|x_{k-1}, E_k = 1, E_{k-1} = 0)P\{E_k = 1|E_{k-1} = 0\} \\ = p_b(x_k)P_b \end{aligned} \quad (4.19)$$

La densité de probabilité de transition $p(x_k|x_{k-1}, E_k = 1, E_{k-1} = 1)$ donnée par l'expression dans (4.18) est définie par le modèle dynamique de la cible (4.1). La fonction de densité de probabilité $p_b(x_k)$ est donnée en (4.19) indique la densité initiale de la cible sur son apparence. Dans le cadre bayésien, cette densité est supposée connue (par exemple, on peut supposer une densité uniforme sur toute la zone de surveillance).

4.2.4.2 Mise à jour (Correction)

Conceptuellement, l'équation de la mise à jour dans le cadre bayésien est donnée par :

$$p(x_k, E_k = 1|z_{1:k}) = \frac{p(z_k|x_k, E_k = 1)p(x_k, E_k = 1|z_{1:k-1})}{p(z_k|z_{1:k-1})} \quad (4.20)$$

Où la densité de la prédiction $p(x_k, E_k = 1|z_{1:k-1})$ est donnée par (4.20) et $p(z_k|x_k, E_k)$ est la fonction de vraisemblance.

4.2.4.1 La fonction de vraisemblance pour les mesures images

Pour le modèle de capteur qui fournis des mesures images décrit dans la section précédente, la fonction de de vraisemblance peut s'exprimer de la manière suivante [42]:

$$p(z_k | x_k, E_k) = \begin{cases} \prod_{i=1}^n \prod_{j=1}^m p_{S+N} \left(z_k^{(i,j)} | x_k \right), & \text{for } E_k = 1 \\ \prod_{i=1}^n \prod_{j=1}^m p_N \left(z_k^{(i,j)} \right), & \text{for } E_k = 0 \end{cases} \quad (4.21)$$

$p_N \left(z_k^{(i,j)} \right)$ est la fonction de la densité de probabilité du bruit de fond en pixel (i, j) , tandis que $p_{S+N} \left(z_k^{(i,j)} | x_k \right)$ est la vraisemblance de signal cible plus bruit en pixel (i, j) , étant donné que la cible est dans l'état x_k . On a pu assumer l'indépendance des mesures de pixels dans (4.21), car le bruit de mesure $\omega_k^{(i,j)}$ en (4.8) est indépendant de pixel à pixel. Les deux fonctions de densité de probabilité $p_N \left(z_k^{(i,j)} \right)$ et $p_{S+N} \left(z_k^{(i,j)} | x_k \right)$ peuvent s'exprimer comme suit :

$$p_N \left(z_k^{(i,j)} \right) = \mathcal{N} \left(z_k^{(i,j)}, 0, \sigma^2 \right) \quad (4.22)$$

$$p_{S+N} \left(z_k^{(i,j)} | x_k \right) = \mathcal{N} \left(z_k^{(i,j)}, h_k^{(i,j)}, \sigma^2 \right) \quad (4.23)$$

Comme la cible (si elle est présente) affecte seulement les pixels dans la zone de son emplacement (x_k, y_k) , l'expression de $p(z_k | x_k, E_k = 1)$ peut approximer comme suit :

$$p(z_k | x_k, E_k = 1) \approx \prod_{i \in C_i(x_k)} \prod_{j \in C_j(x_k)} p_{S+N} \left(z_k^{(i,j)} | x_k \right) \prod_{i \notin C_i(x_k)} \prod_{j \notin C_j(x_k)} p_N \left(z_k^{(i,j)} \right) \quad (4.24)$$

Où $C_i(x_k)$ et $C_j(x_k)$ sont les ensembles d'indices i et j , respectivement, correspond à des pixels affectés par la cible.

A cet effet, nous devons introduire le rapport de vraisemblance en pixel (i, j) pour une cible dans l'état x_k^n , défini comme :

$$\ell \left(z_k^{(i,j)} | x_k^n \right) \triangleq \frac{p_{S+N} \left(z_k^{(i,j)} | x_k^n \right)}{p_N \left(z_k^{(i,j)} \right)}$$

(4.25)

$$= \exp \left\{ - \frac{h_k^{(i,j)} (h_k^{(i,j)} - 2z_k^{(i,j)})}{2\sigma^2} \right\} \quad (4.26)$$

Où $h_k^{(i,j)}$ est défini en (4.9). L'équation (4.26) résulte de (4.22), (4.23), et (4.25). Les poids d'importance (jusqu'à constante de normalisation) sont maintenant donnés par [42]:

$$\tilde{\omega}_k^n = \begin{cases} \prod_{i \in C_i(x_k^n)} \prod_{j \in C_j(x_k^n)} \ell \left(z_k^{(i,j)} | x_k^n \right) & \text{if } E_k^n = 1 \\ 1 & \text{if } E_k^n = 0 \end{cases} \quad (4.27)$$

4.2.4.2 La fonction de vraisemblance pour les mesures radar

Pour le de radar qui fournis des mesures en coordonnées polaire décrit dans la section précédente, la fonction de de vraisemblance peut s'exprimer de la manière suivante [116][49]:

$$p(z_k | x_k, E_k) = \begin{cases} \prod_{i=1}^{N_r} \prod_{j=1}^{N_r} \prod_{\ell=1}^{N_\theta} p(z_k^{(i,j,\ell)} | x_k, E_k = 1), & \text{for } m_k = 1 \\ \prod_{i=1}^{N_r} \prod_{j=1}^{N_r} \prod_{\ell=1}^{N_\theta} p(z_k^{(i,j,\ell)} | E_k = 0), & \text{for } m_k = 0 \end{cases} \quad (4.28)$$

Où $p(z_k^{(i,j,\ell)} | E_k = 0)$ est défini comme la fonction de densité de probabilité du bruit de fond dans la cellule (i, j, ℓ) , tan dis que $p(z_k^{(i,j,\ell)} | x_k, E_k = 1)$ est défini comme la vraisemblance du signal de la cible plus le bruit dans la cellule (i, j, ℓ) , ainsi que la cible est dans l'état x_k . Supposant que le bruit de mesure est gaussien, et indépendant de cellule à cellule, les deux fonctions de densité de probabilité peuvent alors être données de la manière suivantes :

$$p(z_k^{(i,j,\ell)} | x_k, E_k = 1) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{[z_k^{(i,j,\ell)} - \Psi^{(i,j,\ell)}(x_k)]^2}{2\sigma^2}\right) \quad (4.29)$$

$$p(z_k^{(i,j,\ell)} | E_k = 0) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{[z_k^{(i,j,\ell)}]^2}{2\sigma^2}\right) \quad (4.30)$$

En considérant que la cible affecte seulement les cellules situés à proximité de son emplacement (x_k, y_k) , la densité $p(z_k | x_k, E_k = 1)$ peut s'exprimer comme suit :

$$\begin{aligned} (z_k | x_k, E_k = 1) &\approx \prod_{i \in \alpha_i(x_k)} \prod_{j \in \alpha_j(x_k)} \prod_{\ell \in \alpha_\ell(x_k)} p(z_k^{(i,j,\ell)} | x_k, E_k = 1) \cdot \\ &\prod_{i \notin \alpha_i(x_k)} \prod_{j \notin \alpha_j(x_k)} \prod_{\ell \notin \alpha_\ell(x_k)} p(z_k^{(i,j,\ell)} | E_k = 0) \end{aligned} \quad (4.31)$$

Où $\alpha_i(x_k)$, $\alpha_j(x_k)$ et $\alpha_\ell(x_k)$ sont les ensembles de tous les numéros de cellules de la portée, de la vitesse radiale et d'angle azimutal, respectivement, relatifs aux numéros de cellules affectées par la cible.

Ainsi, pour notre application, nous devons introduire le rapport de vraisemblance dans la cellule (i, j, ℓ) avec une cible dans l'état x_k^n , est donné par :

$$L(x_k^{(i,j,\ell)} | x_k^n, E_k) = \begin{cases} \frac{p(z_k^{(i,j,\ell)} | x_k, E_k = 1)}{p(z_k^{(i,j,\ell)} | E_k = 0)} & E_k = 1 \\ 1 & E_k = 0 \end{cases} \quad (4.32)$$

Nous remplaçons par la fonction de densité de probabilité de $p(z_k^{(i,j,\ell)} | x_k, E_k = 1)$ et $p(z_k^{(i,j,\ell)} | E_k = 0)$, nous avons trouvé :

$$L(z_k^{(i,j,\ell)} | x_k, E_k) = \begin{cases} \exp\left\{-\frac{\Psi_k^{(i,j,\ell)}(x_k)(\Psi_k^{(i,j,\ell)}(x_k) - 2z_k^{(i,j,\ell)})}{2\sigma^2}\right\} & E_k = 1 \\ 1 & E_k = 0 \end{cases} \quad (4.33)$$

Où $\Psi_k^{(i,j,\ell)}$ est défini par (4.13) et l'équation (4.33) résulte de (4.29), (4.30), and (4.32), donc rapport de vraisemblance peut s'exprimer comme suit :

$$p\left(z_k^{(i,j,\ell)} \mid x_k, E_k\right) = \begin{cases} \prod_{i \in \alpha_i(x_k)} \prod_{j \in \alpha_j(x_k)} \prod_{\ell \in \alpha_\ell(x_k)} \exp\left\{-\frac{\Psi_k^{(i,j,\ell)}(x_k)(\Psi_k^{(i,j,\ell)}(x_k) - 2z_k^{(i,j,\ell)})}{2\sigma^2}\right\} & E_k = 1 \\ 1 & E_k = 0 \end{cases} \quad (4.34)$$

Ainsi, pour atteindre notre objectif, nous devons calculer les poids d'importance $\tilde{\omega}_k^n$ en utilisant le rapport de vraisemblance [116]:

$$\tilde{\omega}_k^n = \begin{cases} \prod_{i \in \alpha_i(x_k^n)} \prod_{j \in \alpha_j(x_k^n)} \prod_{\ell \in \alpha_\ell(x_k^n)} L\left(z_k^{(i,j,\ell)} \mid x_k^n\right) & \text{if } E_k^n = 1 \\ 1 & \text{if } E_k^n = 0 \end{cases} \quad (4.35)$$

4.2.5 Implémentation de filtre particulaire

La solution bayésienne récursive du problème Track-Before-Detect décrit dans la section précédente est implémentée en utilisant un filtre particulaire [42][110][117]. Le filtre particulaire que nous développons pour cette application utilise l'estimation hybride qui est déjà présentée dans le chapitre 3 (paragraphe 3.8.4), où le vecteur d'état est augmenté pour incorporer la variable d'existence comme suit $y_k = [x_k^T \ E_k]^T$. Donc, l'algorithme d'un seul cycle de filtre particulaire utilisé dans notre travail nommé par TBD-PF pour différents types de modèle de mouvement. L'Algorithme est défini par les étapes suivantes :

Etape (1) : Générer un ensemble de N particules $\{y_{k-1}^n, \omega_{k-1}^n\}_{n=1}^N$ avec des poids ω_{k-1}^n uniformes.

Etape (2) : Générer variable d'existence E_k utilisant la matrice de transition donnée par l'équation (4.7).

Etape (3) : La première étape est de prédire la variable d'existence de la cible E_k^n , $n = 1, \dots, N$ pour chaque particule en utilisant l'algorithme (A-2) de Régime transitoire décrit dans l'annexe. Ensuite, la prédiction des particules des états de cible se fait seulement pour les particules qui sont caractérisées par $E_k^n = 1$ et pour les particules restantes (avec $E_k^n = 0$), les composantes de l'état de la cibles ne sont pas définies. Dans ce cas il existe deux possibilités :

- *Les particules naissantes* : Ce groupe de particules prédites est défini par la transition de $E_{k-1}^n = 0$ à $E_k^n = 1$. Les particules de l'état de la cible sont représentées suivant loi uniforme par la densité de proposition $q_b = (x_k | E_k^n = 1, E_{k-1}^n = 0, z_k)$ à l'instant k . Pour les composantes de la position (x_k, y_k) , les particules sont distribuées suivant la loi uniforme de la zone de surveillance. On suppose que les autres composantes de vecteur d'état (vitesse, accélération et l'intensité) suivent la loi uniforme et leurs densités de proposition données par : $q_b(\dot{x}_k^n, \dot{y}_k^n | z_k) = \mathcal{U}[-v_{min}, v_{max}]$, $q_b(\ddot{x}_k^n, \ddot{y}_k^n | z_k) = \mathcal{U}[-a_{min}, a_{max}]$ et $q_b(I_k | z_k) = \mathcal{U}[I_{min}, I_{max}]$, où v_{min} et v_{max} sont les valeurs minimale et maximale de la vitesse de la cible, respectivement ainsi que a_{min} et a_{max} sont les valeurs minimale et maximale de l'accélération de la cible, respectivement, enfin I_{min} et I_{max} sont les niveaux minimal et maximal de l'intensité dûment choisis (basés sur le rapport signal sur bruit espéré).
- *Particules existantes* : Ceci constitue d'un groupe de particules qui continue de rester "en vie", avec la transition $E_{k-1}^n = 1$ et $E_k^n = 1$. Le modèle dynamique de la cible dans l'équation (1) est utilisé pour la mise à jour des particules d'état de la cibles.

Etape (4) : Calculer les poids normalisés utilisant : $\omega_k^n = \frac{\tilde{\omega}_k^n}{\sum_{n=1}^N \tilde{\omega}_k^n}$

Etape (5) : calculer la taille effective de l'échantillon par : $N_{eff} = \frac{1}{\sum_{n=1}^N (\omega_k^n)^2}$

Etape (6) : faire le test de dégénérescence $N_{eff} < N_{th}$

Etape(7) : le Ré-échantillonnage de N particules

$$\left[\left\{ y_k^n, \frac{1}{N} \right\}_{n=1}^N \right] = \text{rééchantillonnage}[\{y_k^m, \omega_k^m\}_{n=1}^N]$$

Le pseudocode d'un seul cycle de l'algorithme TBD-PF est présenté dans le table (4-1).

$$[\{y_k^n, \omega_k^n\}_{n=1}^N] = TBD - PF[\{y_{k-1}^n, \omega_{k-1}^n\}_{n=1}^N, z_k]$$

- Régime transitoire (Table A-2)

$$[\{E_k^n\}_{n=1}^N = RT[\{E_{k-1}^n\}_{n=1}^N, \Pi]]$$

- Pour $n = 1:N$

- * Si $E_{k-1}^n = 0$ et $E_k^n = 1$ (particule naissante) :

Tirer $x_k^n \sim q_b(x_k | z_k)$

- * Si $E_{k-1}^n = 1$ et $E_k^n = 1$ (particule existante) :

Tirer $x_k^n \sim q(x_k | x_{k-1}^n, z_k)$

- * Evaluer le poid d'importance $\tilde{\omega}_k^n$

- Fin pour

- Normalisation des poids $\omega_k^n = \frac{\tilde{\omega}_k^n}{\sum_{n=1}^N \tilde{\omega}_k^n}$

- faire le test de dégénérescence $N_{eff} < N_{th}$

- Re-échantillonnage utilisant l'algorithme de la Table (3-2) :

$$\left[\left\{ y_k^n, \frac{1}{N} \right\}_{n=1}^N \right] = \text{rééchantillonnage}[\{y_k^m, \omega_k^m\}_{n=1}^N]$$

Table 4-1 Filtre particulaire pour Track-Before-Detect (PF-TBD)

Etape(8) : les Sorties de l'algorithme PF-TBD : Le filtre (PF-TBD) effectue la détection de la cible en utilisant l'estimation de la probabilité d'existence a posteriori à l'instant k définie dans (4.16) de la manière suivante :

$$\hat{P}_k = \frac{\sum_{n=1}^N E_k^n}{N} \quad (4.36)$$

et lorsque cette valeur est supérieure à une certaine valeur du seuil τ , une cible est supposée détectée $\hat{P}_k > \tau$. Le choix d'un bon seuil est une sorte de compromis entre les fausses alarmes, c'est-à-dire le dépassement du seuil lorsqu'aucune cible n'est présente, et la probabilité de détection, c'est-à-dire que la probabilité d'existence d'une cible dépasse le seuil lorsque la cible est présent. Quelques éléments de base peuvent être trouvés dans [118].

avec $0 \leq \hat{P}_k \leq 1$. cette déclaration peut alors déclencher l'initialisation d'une piste en fonction de l'état estimé de la cible :

$$\hat{x}_{k|k} = \frac{\sum_{n=1}^N x_k^n E_k^n}{\sum_{n=1}^N E_k^n} \quad (4.37)$$

4.1 Simulations et commentaires de l'algorithme PF-TBD (Les mesures Images)

La formulation du modèle dynamique générale est donnée par l'équation (4.1), pour simplifier la présentation, Nous supposons qu'on veut suivre une cible mobile se déplaçant dans un plan 2D avec un vecteur d'état inconnu x_k à l'instant k . Nous considérons le modèle d'état discret donné par

$$x_{k+1} = Fx_k + v_k \quad (4.38)$$

Où F est la matrice de transition, v_k est un processus de bruit gaussien à une moyenne nulle et une covariance Q . k est l'indice de temps discret et x_k représente le vecteur d'état défini dans les modèles de mouvement.

Nous avons simulé l'algorithme PF-TBD pour les mesures images utilisant trois modèles de mouvements comme donnée dans le paragraphe suivante et voir aussi les références [119] [120].

4.1.1 Cible non-manouvrante

4.1.1.1 Scénario 1 (Modèle CV)

Considérant une cible mobile à faible rapport signal sur bruit (par exemple une cible à faible SER) suit un mouvement rectiligne de modèle dynamique à vitesse constante (CV) [121][122]. Le modèle dynamique discret est donné par l'expression (4.38).

Le modèle à vitesse constante (CV) est caractérisé par la matrice de transition F_{CV} donnée par

$$F_{CV} = \begin{bmatrix} 1 & T & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & T & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.39)$$

et un bruit blanc gaussien v_k de moyenne nulle et de covariance Q_{CV} donnée par :

$$Q_{CV} = \begin{bmatrix} \frac{q_1}{3} T^3 & \frac{q_1}{2} T^2 & 0 & 0 & 0 \\ \frac{q_1}{2} T^2 & q_1 T & 0 & 0 & 0 \\ 0 & 0 & \frac{q_1}{3} T^3 & \frac{q_1}{2} T^2 & 0 \\ 0 & 0 & \frac{q_1}{2} T^2 & q_1 T & 0 \\ 0 & 0 & 0 & 0 & q_2 T \end{bmatrix} \quad (4.40)$$

Où T est le temps d'échantillonnage. q_1 et q_2 représentent le niveau du processus de bruit de mouvement et de l'intensité de la cible, respectivement.

On considère une séquence de 30 images est générée avec les paramètres suivantes : $\Delta_x = \Delta_y = 1, n = m = 20, T = 1s, \sigma = 3$. La cible est absente de l'image 1 à l'image 6, et apparaît dans le frame 8 avec une intensité initiale $I_0 = 14, 20, 30$ correspond à $RSB = 3.18, 6.71, \sim 11$, respectivement. $\Sigma = 0.7$ est le paramètre de flou d'image. Le RSB initial est donné par :

$$RSB = 10 \log \left[\frac{I_0 \Delta_x \Delta_y / 2\pi \Sigma^2}{\sigma} \right]^2$$

La position et la vitesse initiale de la cible sont données par (4.2, 7.2) m, (0.45, 0.25) m/s, respectivement. Le niveau de bruit utilisé dans le mouvement de la cible / modèle d'intensité est: $q_1 = 0.001$ et $q_2 = 0.01$ (faible variation de RSB). La cible est absente entre l'image 1 et 6 ensuite elle existe jusqu'au frame 25 et elle est de nouveau absente dans les images 26, 27, ..., 30. La figure (4-3) présente six images de la séquence de mesures (les images 2, 8, 14, 18, 26 et 27) synthétisé selon le procédé expérimental décrit précédemment. Cette séquence d'images sert à illustrer que par examen visuel, il est impossible de détecter l'existence et déduire l'emplacement de la cible.



Figure 4-3 Sélection de six images au sein d'une séquence de mesures à 6.71 dB

Les paramètres de filtres particulaire sont données comme suit : les probabilités de transition $P_b = P_d = 0.05$; probabilité d'existence initiale $\mu_1 = 0.05$; $v_{\min} = -1$ m/s; $v_{\max} = 1$ m/s; l'intensité initiale est donnée par $I_{\min} = 10$ to $I_{\max} = 3030$ (correspondant à RSB cible de 3.61 dB à ~ 11 dB) ; le nombre des pixels affecté par la cible est donné par $p = 2$ et le nombre des particules $N = 2000$.

La probabilité d'existence du modèle CV est présentée par la figure (4-4) pour une valeur de $RSB = 6.71$ dB. La probabilité d'existence estimée est très faible entre l'image 1 et 5 lorsque la cible est absente, ensuite elle augmente et elle reste stable et proche de la valeur théorique après l'image 6 et jusqu'à l'image 25 lorsque la cible apparaît puis elle diminue dans l'image 26 jusqu'à la fin de la séquence, lorsque la cible disparaît.

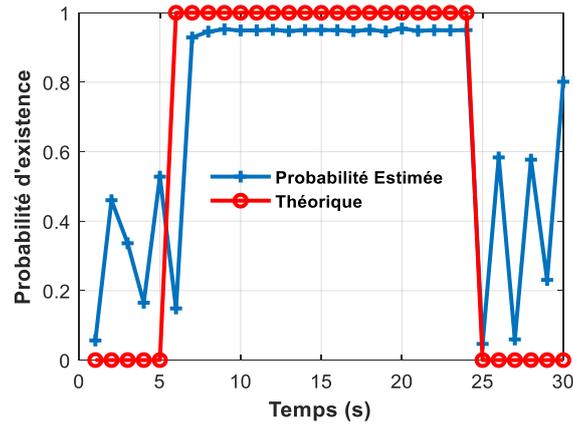


Figure 4-4 Probabilité d'existence pour RSB=6.71

La figure (4-5) illustre la trajectoire réelle et la trajectoire estimée d'une cible à un faible $RSB = 6.71$ dB. Notez comment la trajectoire de la cible dévie légèrement de la trajectoire rectiligne (modèle CV) en raison du bruit de processus. Le PF-TBD suit la cible avec une petite erreur de position.

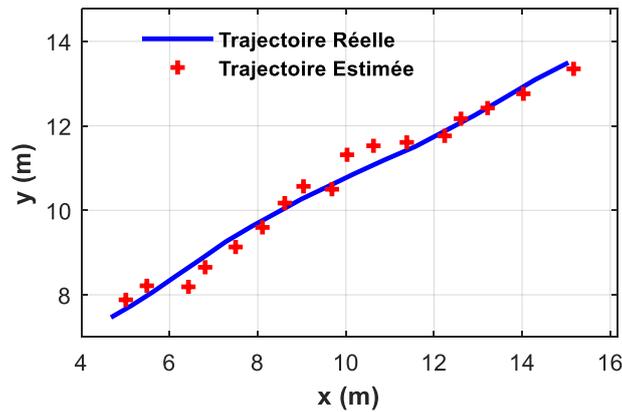


Figure 4-5 La trajectoire réelle vers la trajectoire estimée à RSB=6.71 dB

La figure (4-6) montre l'erreur de position RMSE pour trois valeurs RSB (3.18 dB, 6.71 dB, 11 dB). L'erreur de position à 6.71 dB est inférieure à l'erreur de position à 3.18 dB. Comme on peut le voir, le PF-TBD est capable de suivre la cible sous un faible RSB.

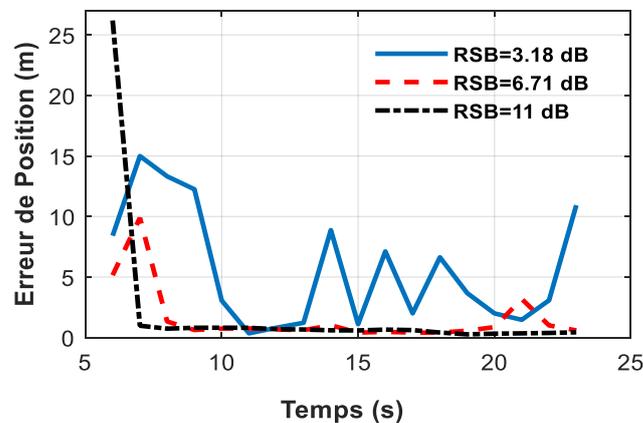


Figure 4-6 Les erreurs de position pour différents valeur RSB

4.1.2 Cible manouvrantes

4.1.2.1 Scénario 1 (Modèle CT)

Une cible mobile à faible rapport sur bruit suit un mouvement curviligne de modèle dynamique à virage (coordinate turn CT) avec une vitesse quasi-constante v et un taux de rotation fixe Ω . Supposons que Ω est connu et mène à un vecteur d'état dans les coordonnées cartésiennes $s_k = [x_k \ \dot{x}_k \ y_k \ \dot{y}_k \ I_k]^T$. Le modèle CT est linéaire car Ω est considéré connu donné par $\Omega = 6^\circ/s$, en gardant les mêmes paramètres de simulation de le modèle CT [123]. Le modèle dynamique discret est donné par l'expression (4.38).

Le modèle à virage (CT) est caractérisé par la matrice de transition F_{CT} donnée par

$$F_{CT} = \begin{bmatrix} 1 & \frac{\sin \Omega T}{\Omega} & 0 & -\frac{(1-\cos \Omega T)}{\Omega} & 0 \\ 0 & \cos \Omega T & 0 & -\sin \Omega T & 0 \\ 0 & \frac{(1-\cos \Omega T)}{\Omega} & 1 & \frac{\sin \Omega T}{\Omega} & 0 \\ 0 & \sin \Omega T & 0 & \cos \Omega T & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.41)$$

et un bruit blanc gaussien v_k de moyenne nulle et de covariance Q_{CT} donnée par

$$Q_{CT} = \begin{bmatrix} \frac{2q_1(\Omega T - \sin \Omega T)}{\Omega^3} & \frac{q_1(1-\cos \Omega T)}{\Omega^2} & 0 & \frac{q_1(\Omega T - \sin \Omega T)}{\Omega^2} & 0 \\ \frac{q_1(1-\cos \Omega T)}{\Omega^2} & q_1 T & -\frac{q_1(\Omega T - \sin \Omega T)}{\Omega^2} & 0 & 0 \\ 0 & -\frac{q_1(\Omega T - \sin \Omega T)}{\Omega^2} & \frac{2q_1(\Omega T - \sin \Omega T)}{\Omega^3} & \frac{q_1(1-\cos \Omega T)}{\Omega^2} & 0 \\ \frac{q_1(\Omega T - \sin \Omega T)}{\Omega^2} & 0 & \frac{q_1(1-\cos \Omega T)}{\Omega^2} & q_1 T & 0 \\ 0 & 0 & 0 & 0 & q_2 T \end{bmatrix} \quad (4.42)$$

La figure (4-7) présente deux images de la séquence de mesures (les images 4, 20) synthétisé selon le procédé expérimental décrit précédemment. Cette séquence d'images sert à illustrer que par examen visuel, il est impossible de détecter l'existence et déduire l'emplacement de la cible à un faible RSB de 6.71 dB.

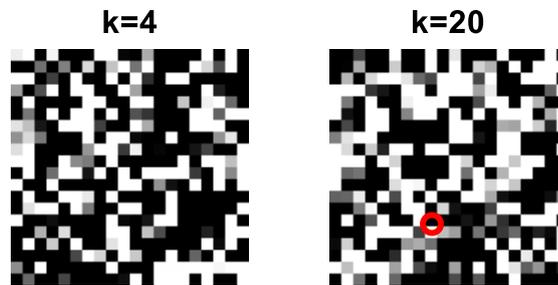


Figure 4-7 deux images au sein d'une séquence de mesures à 6.71 dB

La probabilité d'existence du modèle CT est présentée par la figure (4-8) pour une valeur de $RSB = 6.71$ dB. La probabilité d'existence estimée est très faible entre l'image 1 et 5 lorsque la cible est absente, ensuite elle augmente jusqu'à 0.9 et elle reste un peu stable et proche de la valeur théorique après l'image 12 et jusqu'à l'image 25 lorsque la cible apparaît puis elle

diminue et devient presque nulle dans l'image 26 jusqu'à la fin de la séquence, lorsque la cible disparaît.

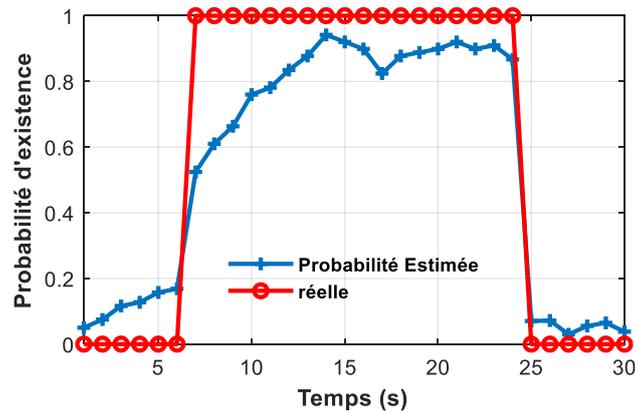


Figure 4-8 Probabilité d'existence pour RSB=6.71

La figure (4-9) illustre la trajectoire réelle et la trajectoire estimée d'une cible à un faible $RSB = 6.71$ dB. Notez comment la trajectoire de la cible dévie légèrement de la trajectoire curviligne réelle en raison du bruit de processus. Le PF suit la cible avec une petite erreur de position.

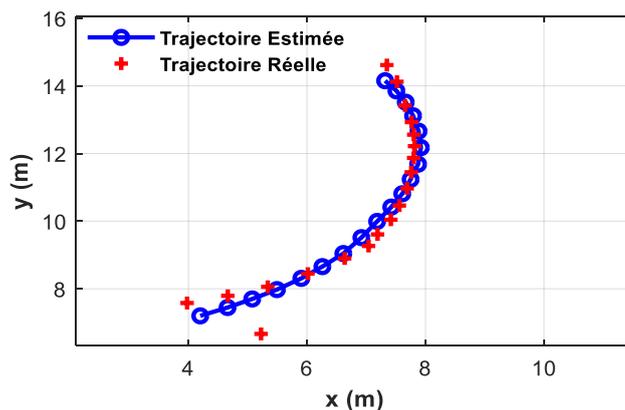


Figure 4-9 La trajectoire réelle vers la trajectoire estimée pour RSB=6.71 dB

La figure (4-10) montre l'erreur de position RMSE pour trois valeurs RSB (3.18 dB, 6.71 dB, 12 dB). L'erreur de position à 6.71 dB est inférieure à l'erreur de position à 3.18 dB. Comme on peut le voir, le PF-TBD est capable de suivre la cible sous un faible RSB.

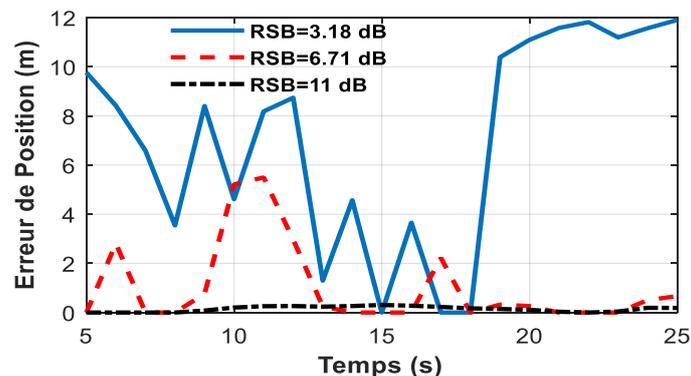


Figure 4-10 Les erreurs de position pour différentes valeur RSB

4.1.2.1 Scénario 2 (Modèle CA)

Supposons que le mouvement consiste un modèle d'accélération du processus de Wiener [9]. Le processus de Wiener a été considéré comme une accélération. D'autre part, pour plus de précision, l'accélération considérée comme un processus à incréments indépendants, ce qui n'est pas essentiellement envisager un processus de Wiener. On peut définir le modèle d'accélération constante (CA) [85][120] par (4.38). Où le vecteur d'état se compose de la position (x_k, y_k) , la vitesse (\dot{x}_k, \dot{y}_k) , l'accélération (\ddot{x}_k, \ddot{y}_k) et l'intensité I_k , respectivement comme suit : $s_k = [x_k \ \dot{x}_k \ \ddot{x}_k \ y_k \ \dot{y}_k \ \ddot{y}_k \ I_k]^T$. La matrice de transition F_{CA} et la covariance du processus de bruit Q_{CA} sont données par :

$$F_{CA} = \begin{bmatrix} 1 & T & T^2/2 & 0 & 0 & 0 & 0 \\ 0 & 1 & T & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & T & T^2/2 & 0 \\ 0 & 0 & 0 & 0 & 1 & T & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.43)$$

$$Q_{CA} = \begin{bmatrix} \frac{q_1 T^5}{20} & \frac{q_1 T^4}{8} & \frac{q_1 T^3}{6} & 0 & 0 & 0 & 0 \\ \frac{q_1 T^4}{8} & \frac{q_1 T^3}{3} & \frac{q_1 T^2}{2} & 0 & 0 & 0 & 0 \\ \frac{q_1 T^3}{6} & \frac{q_1 T^2}{2} & T & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{q_1 T^5}{20} & \frac{q_1 T^4}{8} & \frac{q_1 T^3}{6} & 0 \\ 0 & 0 & 0 & \frac{q_1 T^4}{8} & \frac{q_1 T^3}{3} & \frac{q_1 T^2}{2} & 0 \\ 0 & 0 & 0 & \frac{q_1 T^3}{6} & \frac{q_1 T^2}{2} & T & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & q_2 T \end{bmatrix} \quad (4.44)$$

La figure (4-11) présente deux images de la séquence de mesures (les images 4, 20) synthétisé selon le procédé expérimental décrit précédemment. Ces deux images servent à illustrer que par examen visuel, il est impossible de détecter l'existence et déduire l'emplacement de la cible à un faible RSB de 6.71 dB.

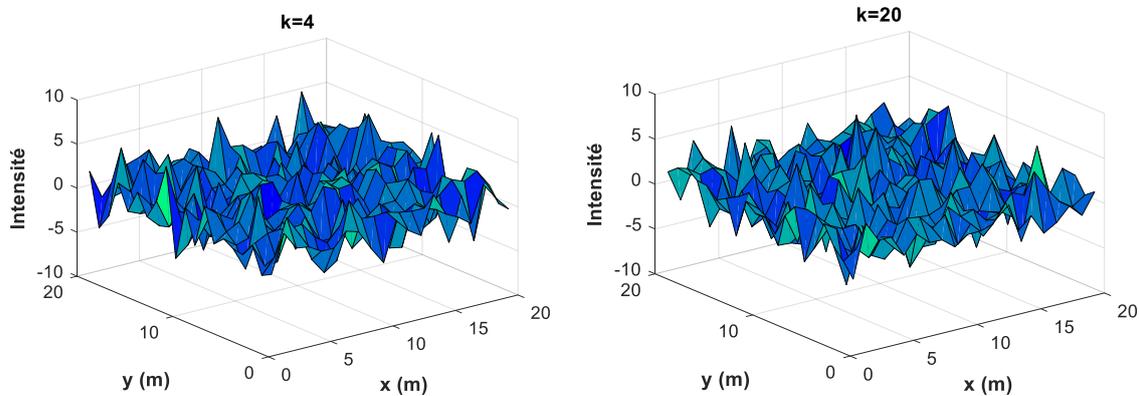


Figure 4-11 deux images au sein d'une séquence de mesures à 6.71 dB

La probabilité d'existence du modèle CA est présentée par la figure (4-12) pour un $RSB=6.71$ dB. La probabilité d'existence estimée est très faible entre l'image 1 et 5 lorsque la cible est absente, ensuite elle augmente jusqu'à 0.9 et elle reste un peu stable et proche de la valeur théorique après l'image 16 et jusqu'à l'image 25 lorsque la cible apparaît puis elle diminue et devient presque nulle dans l'image 26 jusqu'à la fin de la séquence, lorsque la cible disparaît.

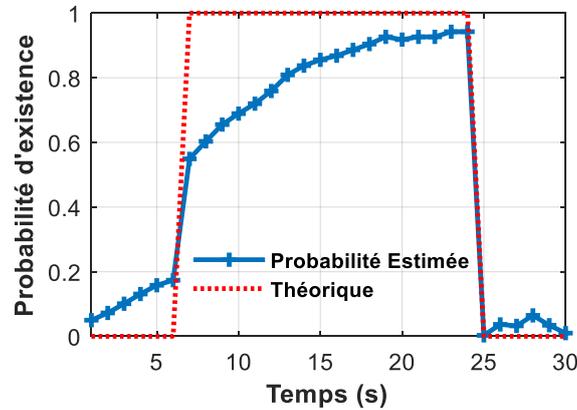


Figure 4-12 Probabilité d'existence pour $RSB=6.71$

La figure (4-13) illustre la trajectoire réelle et la trajectoire estimée d'une cible à un faible $RSB = 6.71$ dB. Notez comment la trajectoire de la cible dévie légèrement de la trajectoire réelle en raison du bruit de processus. Le PF suit la cible avec une petite erreur de position.

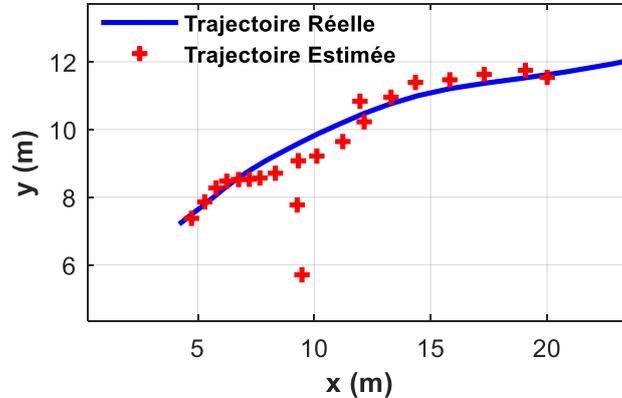


Figure 4-13 La trajectoire réelle vers la trajectoire estimée pour $RSB=6.71$ dB

La figure (4-14) montre l'erreur de position RMSE pour trois valeurs RSB (3.18 dB, 6.71 dB, 12 dB). L'erreur de position à 6.71 dB est inférieure à l'erreur de position à 3.18 dB. Comme on peut le voir, le PF-TBD est capable de suivre la cible sous un faible RSB de 6.71 dB.

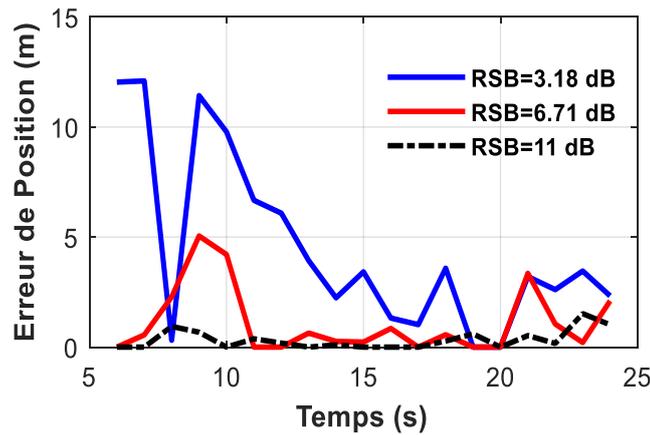


Figure 4-14 Les erreurs de position pour différents valeur RSB

4.2 Simulations et commentaires de l'algorithme PF-TBD (les mesures Radar)

Dans cette partie de simulation, nous considérons un modèle de mesure radar, nous supposons deux scénarios de poursuite de cible manouvrantes dans lesquels les paramètres de la cible (position, vitesse, accélération,...) sont estimés en utilisant un modèle à accélération constante (CA) et un modèle à virage (CT) [85][116]. Les données de mesure simulées se composent d'une séquence de mesure de 30 s. La cible est absente de l'instant 1 à 5 et est présente de l'instant 6 à 25 avant de disparaître de l'instant 26 à 30. Les positions et les vitesses initiales pour les modèles CA et CT sont (4.2,7.2) m, (0.45,0.25) ms^{-1} et (0.2,0.2) $\text{m} \cdot \text{s}^{-2}$, (4.2, 7.2)m et (0.45,0.25) ms^{-1} respectivement. Les paramètres de variance du processus de bruit utilisé dans le modèle de mouvement cible sont $q_1 = 0.001$ et $q_2 = 0.01$. Le radar est situé à la position (0,0). Chaque cadre (frame) de mesure est constituée d'un tableau de 3D de ($N_r \times N_{\dot{r}} \times N_{\theta}$) cellules, où $N_r = N_{\dot{r}} = 48$ et $N_{\theta} = 1$; chaque cellule a une résolution de $\Delta_r = 0.51$ m de portée (range), $\Delta_{\dot{r}} = 0.077$ m/s de vitesse angulaire (range-rate), et $\Delta_{\theta} = 0.033$ radians pour l'angle d'azimut. les limites de la portée de la vitesse angulaire de la mesure correspondante se situe dans l'intervalle [0 24] m, [-1.8 1.8] ms^{-1} , respectivement. Où $T = 1$ s est le temps entre les mesures (le temps d'échantillonnage). Les paramètres d'étalement utilisés dans les modèles de mesure sont : $\sigma_r = 1.1$ m, $\sigma_{\dot{r}} = 0.35$ m m/s, $\sigma_{\theta} = 0.06$ radians. La variance du bruit de mesure est $v_k = 2$ et Ω est le taux de rotation constant pour le modèle CT égal à $1.5^\circ/\text{s}$ pour les faibles manouvres et $20^\circ/\text{s}$ pour les fortes manouvres. Le RSB maximal est calculé comme suit : $SNR = \frac{[\Delta_r \Delta_{\dot{r}} \Delta_{\theta} I_k]^2}{((2\pi)^{3/2} \sigma_r \sigma_{\dot{r}} \sigma_{\theta})^2 v_k}$ et les limites RSB sont données par l'intervalle [-3 12]dB.

Les paramètres du filtre particulaire sont données comme suit : Les probabilités de transition pour le processus de Markov sont fixées à $P_b = P_d = 0.05$; probabilité initiale d'existence $p_0 = 0.05$. Initialement, 2000 particules sont uniformément réparties dans l'espace d'état comme dans [124] avec les limites de vitesse, d'accélération et d'intensité données par $[-1 1] \text{ms}^{-1}$, $[-0.5, 0.5] \text{ms}^{-2}$ et $[I_0 - 5, I_0 + 5]$, respectivement. Les résultats de la simulation sont évalués sur une moyenne de 50 exécutions Monte Carlo utilisant un ordinateur puissant de type Intel Xeon (3.47GHz CPU, 24.0 Go RAM).

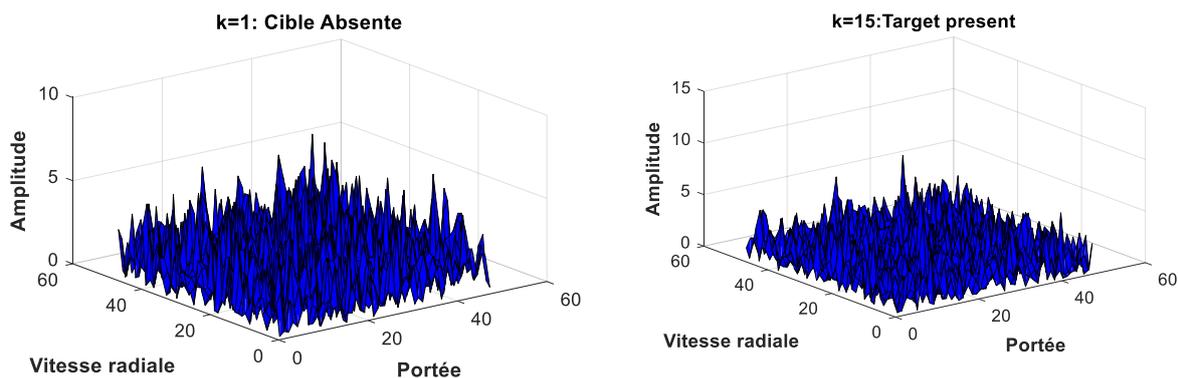
4.2.1 Cible manouvrantes

Les cibles militaires modernes comme les avions sont capables d'effectuer fortes manœuvres en raison de leur conception complexe. Cette capacité de manœuvre comprend des changements soudains d'accélération et de virages qui ne sont pas réalisables par les cibles militaires traditionnels. De plus, les cibles militaires récentes ont généralement une surface équivalente faible, on peut dire aussi ils ont de faible rapport signal / bruit (RSB), ce qui rend la détection et le suivi de ce type de cibles une problématique d'estimation d'état dynamique très compliqué. Dans ce cas, le filtre Track-Before-Detect (TBDF) qui utilise des mesures non seuillées est considéré comme une méthode efficace pour détecter et suivre une cible dans des conditions de faible RSB. Néanmoins, la performance de l'algorithme sera affectée par des pertes importantes en raison de l'inadéquation du modèle de cible pendant la manœuvre. Pour résoudre ce problème, nous proposons une application de filtrage particulaire (PF) dépend de TBD. Dans ce paragraphe Nous présentons les résultats de simulations de filtre PF-TBDF utilisant le modèle d'accélération constante et le modèle de virage coordonné pour des mesures radar comme montré dans la référence [116].

4.2.1.1 Scénario 1 (Modèle CT)

Le premier modèle utilisé est le modèle à virage (CT). La figure (4-15) illustre deux cadres (4 et 15) d'une séquence de mesure qui a été effectuées à un RSB élevé de 12 dB ensuite un à un faible RSB de 6 dB.

Dans la figure (4-15) (a), Ces deux figures servent à illustrer que à un RSB relativement élevé de 12 dB le pic indiquant la présence de la cible est facilement visualisable à l'instant $k = 15$ (cible présente). Donc, nous pouvons facilement détecter la cible à l'aide d'une méthode de détection classique.



(a)

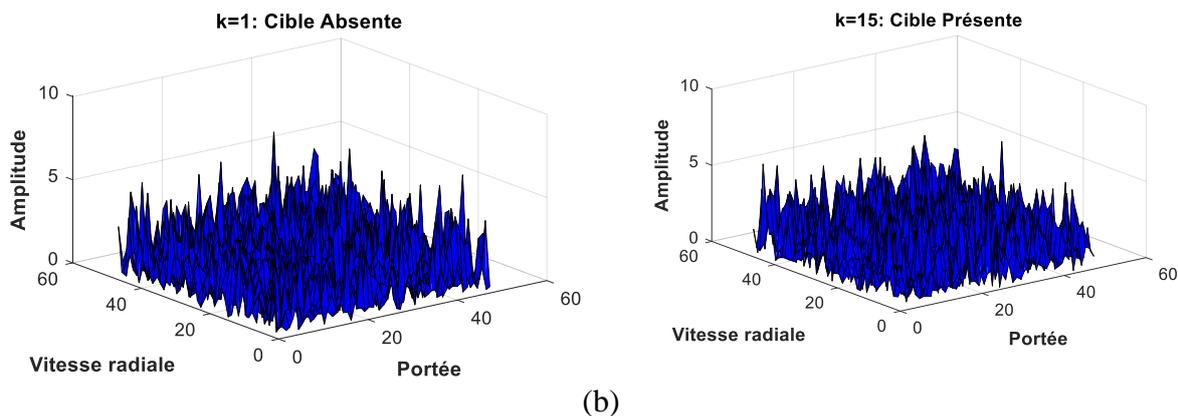


Figure 4-15 Deux frame de mesures (1,15) : (a) pour SNR=12 dB. (b) pour SNR=3 dB

Dans la figure (4-15) (b) une cible à faible rapport signal sur bruit (RSB=3dB) est présente, donc il est très difficile de détecter l'apparition de la cible par la méthode classique.

La figure (4-16) montre l'estimation de la probabilité d'existence du modèle à virage (CT). L'existence d'une cible un RSB élevé est proche de probabilité d'existence théorique avec une dégradation de la performance lorsque le RSB diminue. La probabilité d'existence reste un peu stable après l'instant 16 jusqu'à l'instant 25. Par la suite, elle diminue brusquement à l'instant 26, en raison de la disparitions de la cible.

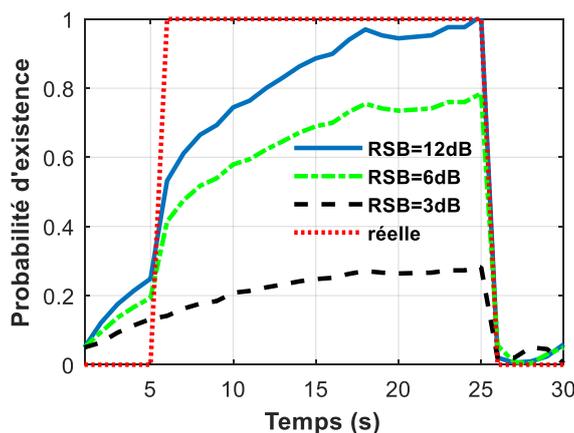


Figure 4-16 La probabilité d'existence de la cible utilisant le modèle CT

La figure (4-17) illustre la trajectoire réelle vers la trajectoire estimée par le filtre PF-TBD. Le paramètre de manœuvrabilité (le taux de rotation) de la cible varie d'une faible valeur de ($2^\circ/s$) à une valeur élevée ($13^\circ/s$) un RSB de 6 dB. Notez comment la trajectoire estimée dévie légèrement de la trajectoire réelle pour le taux de rotation faible. Par contre, l'écart entre les deux trajectoires est plus important quand la valeur de taux de rotation augmente. Par conséquent, même dans des conditions de faible RSB (RSB=6 dB) et avec différents valeur de taux de rotation, le filtre PF-TBD a pu suivre cette cible manouvrante.

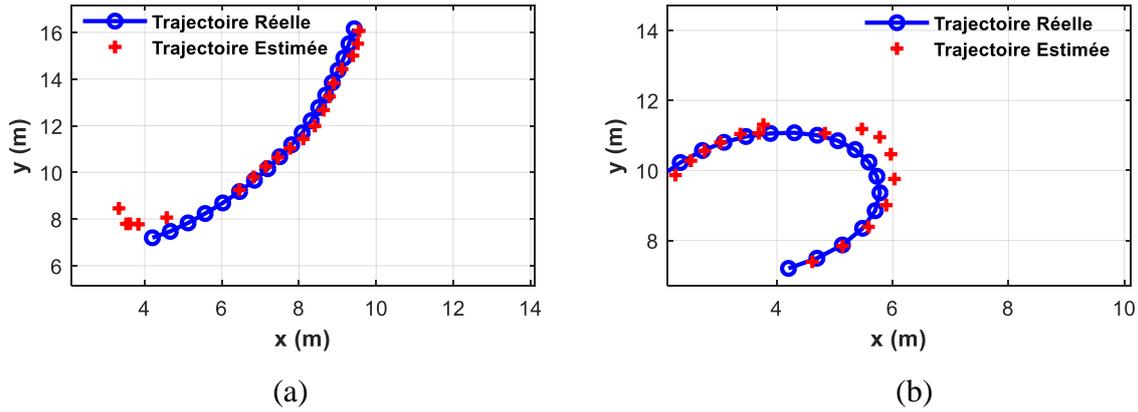


Figure 4-17 La trajectoire réelle vers la trajectoire estimée : (a) faible taux de rotation $2^\circ/s$, (b) taux de rotation levé $13^\circ/s$ pour SNR=6dB

La fiabilité du PF-TBD pour les cibles manouvrantes a été évaluée en introduisant l'erreur quadratique moyenne (RMSE) de position à trois valeurs de RSB=12, 6 et 3 dB, et nous pouvons calculer la RMSE en utilisant l'expression suivante :

$$RMSE = \sqrt{(x_k - \hat{x}_k)^2 + (y_k - \hat{y}_k)^2} \tag{4.45}$$

Où (x_k, y_k) et (\hat{x}_k, \hat{y}_k) sont la position réelle et la position estimée de la cible.

La figure (4-18) montre l'erreur de position (RMSE) où le taux de rotation de la cible varie de d'une faible valeur de $(2^\circ/s)$ à $(13^\circ/s)$ et le rapport signal-à-bruit varie de 3 dB à 12 dB.

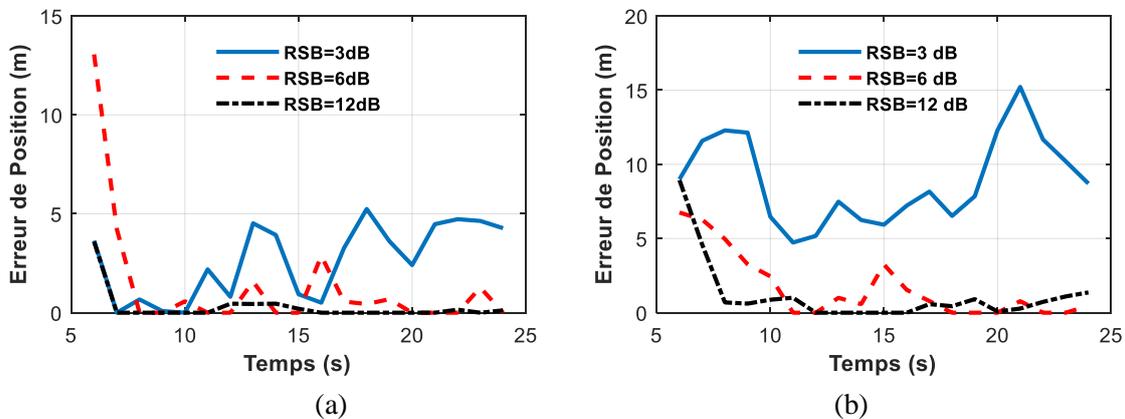


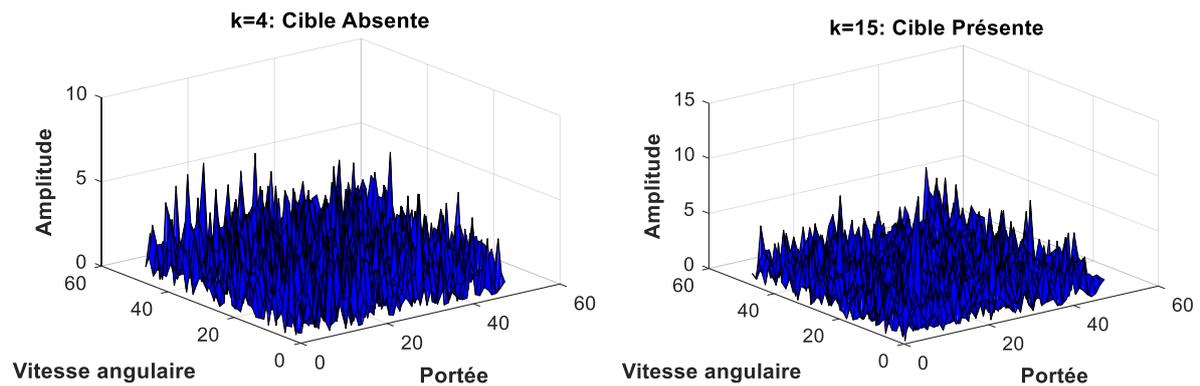
Figure 4-18 L'erreur de position RMSE pour le filtre PF-TBDF : (a) faible taux de rotation $2^\circ/s$, (b) taux de rotation élevé $13^\circ/s$ à SNR= 6dB

On peut remarquer qu'à un RSB=12 dB l'algorithme a un RMSE le plus bas. Cependant, lorsque le RSB réduit le RMSE diminue après quelques instants de l'apparition de la cible. Lorsque le taux de rotation augmente, le RMSE devient plus important, en particulier pour le rapport RSB=3 dB. Par conséquent, le filtre PF-TBD non seuillé est capable de suivre une cible à faible et haut taux de rotation utilisant le modèle CT à faible RSB.

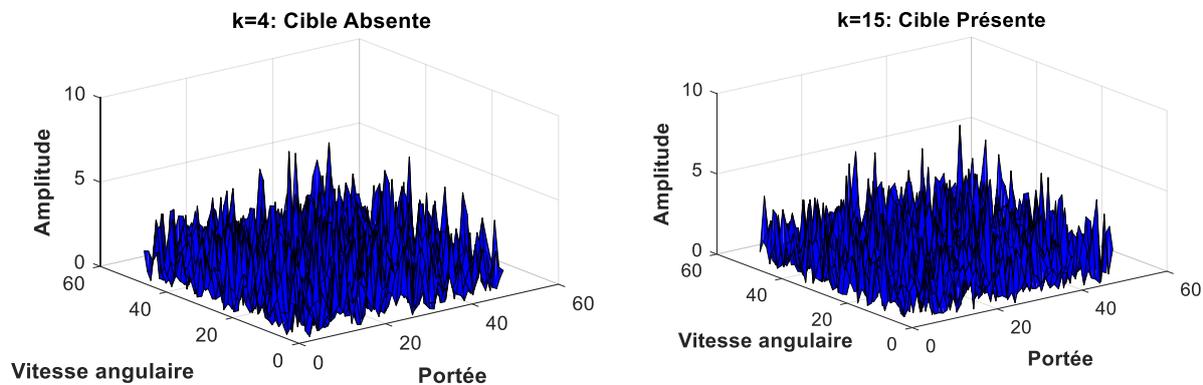
4.2.1.2 Scénario 2 (Modèle CA)

Le deuxième modèle utilisé est le modèle à accélération constante (CA). Comme dans le premier scénario, la figure (4-19) indique deux cadres (4 et 15) d'une séquence de mesure qui a été effectuées à un RSB élevé de 12 dB ensuite un à un faible RSB de 6 dB.

Dans la figure (4-19) (a), Ces deux figures servent à illustrer que à un RSB relativement élevé de 12 dB le pic indiquant la présence de la cible est facilement visualisable à l'instant $k = 15$ (cible présente). Donc, nous pouvons facilement détecter la cible à l'aide d'une méthode de détection classique.



(a)



(b)

Figure 4-19 Frames de mesures (4,15) : (a) pour SNR=12dB (b) pour SNR=6 dB

La figure (4-20) illustre l'estimation de la probabilité d'existence du modèle (CA) à différentes valeurs RSB (12, 6 et 3 dB) utilisant le filtre PF-TBD.

L'existence d'une cible à un RSB élevé est très proche de la probabilité réelle d'existence avec une dégradation de la performance lorsque le RSB diminue. Après l'apparition de la cible dans la région de surveillance, le PF-TBD n'a besoin que de quelques cadres pour établir l'existence de la cible. Ensuite, la probabilité d'existence continue à augmenter après l'instant 7 jusqu'à l'instant 20 et reste relativement stable jusqu'au frame 25. Ensuite, elle diminue rapidement après la disparition de la cible de la zone de surveillance après l'instant 25.

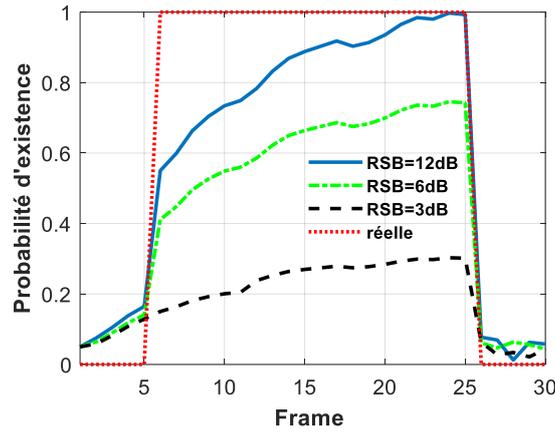


Figure 4-20 La probabilité d'existence de la cible utilisant le modèle CA

La figure (4-21) illustre la trajectoire réelle vers la trajectoire estimée par le filtre PF-TBD. Le paramètre de manœuvrabilité (l'accélération) de la cible passe d'une faible valeur de 0.2 m/s^2 à une valeur élevée de 5 m/s^2 à un RSB=6 dB. On remarque que, les deux trajectoires sont très proches pour la faible manœuvrabilité. Lorsque l'accélération augmente, les deux trajectoires deviennent légèrement distantes. Par conséquent, même dans des conditions de faible RSB (RSB=6 dB) et d'une faible ou haute manœuvrabilité, le filtre PF-TBD a pu suivre cette cible.

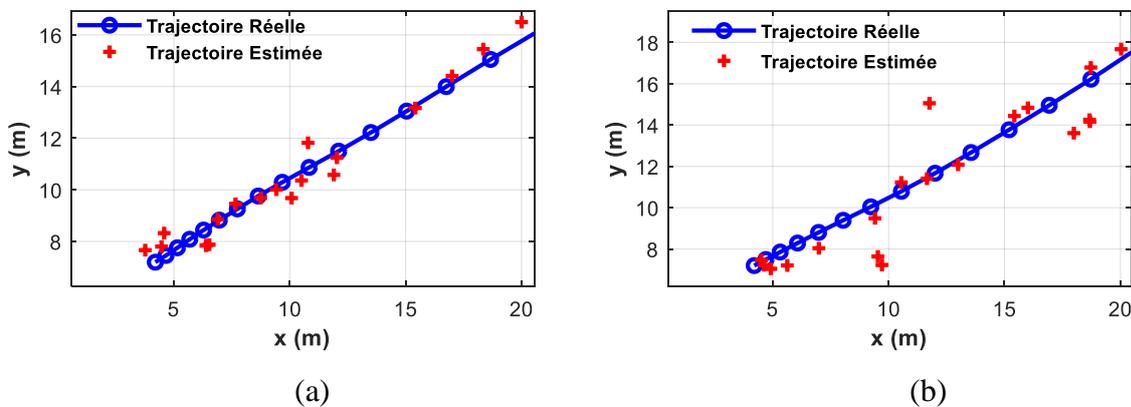


Figure 4-21 Trajectoire réelle et trajectoire estimée : (a) faible accélération 0.2 ms^{-2} , (b) accélération élevée 5 ms^{-2} à SNR=6dB

La figure (4-22) illustre l'estimation de l'erreur de position RMSE de différentes valeurs RSB pour l'algorithme PF-TBDF. Le paramètre de manœuvrabilité de la cible est augmenté de 0.2 ms^{-2} à 5 ms^{-2} pour différentes valeurs de RSB.

On peut remarquer qu'à un RSB=12 dB l'algorithme a un RMSE le plus bas. Cependant, lorsque le SNR est réduit, le RMSE diminue après quelques instants de l'apparition de la cible. Lorsque l'accélération augmente, le RMSE devient plus important, en particulier pour le RSB=3dB. Par conséquent, le filtre PF-TBDF est capable de suivre la cible manœuvrante en utilisant un modèle de CA RSB.

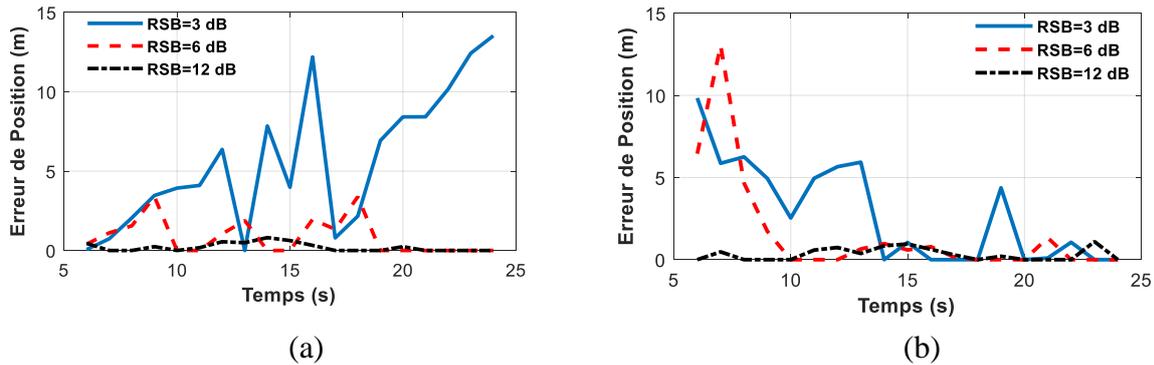


Figure 4-22 L'erreur de position RMSE pour le filtre PF-TBDF : (a) faible accélération 0.2 ms^{-2} , (b) accélération élevé 5 ms^{-2}

4.3 Conclusion

Ce chapitre présente la solution (classique) particulière de problème track before detect mono-cible. Cette solution consiste à considérer un état caché d'estimation hybride (x_k, E_k) , où x_k est l'état cible et E_k est une variable binaire modélisant l'absence ou la présence de la cible, afin de détecter et de suivre conjointement une seule cible. Pour ce modèle d'espace d'états, l'approximation de filtre particulière pour l'approche TBD a été détaillée dans la section (4.2.4). Ce filtre particulier échantillonne deux cas différents : un cas concerne les particules déjà vivantes à l'instant précédent et propagées conformément aux différents modèles dynamique de la cible pour deux types de mesures (les mesure images et les mesures radar); tandis que l'autre cas correspond aux particules naissantes qui doivent être initialisées dans l'espace cible.

Enfin, dans les deux sections (4.1) et (4.2), les simulations de l'algorithme PF-TBD pour fournir des performances de détection et d'estimation de la poursuite mono-cibles utilisant différents modèles de mouvement (CA et CT) et différents types de mesures (des mesures image, des mesures radar) présentés dans ce chapitre. Enfin, une extension l'algorithme PF-TBD sera présentée dans le chapitre suivant pour suivre plusieurs cibles (multi-cible) avec différent modèle d'existence des cibles.

5. L'APPROCHE TRACK-BEFORE-DETECT MULTI-CIBLE

5. L'APPROCHE TRACK-BEFORE-DETECT MULTI-CIBLE	103
5.1 Introduction	104
5.2 L'approche TBD multi-cible	104
5.2.1 Le Modèle d'état multi-cibles	104
5.2.2 Matrice de transition.....	106
5.2.3 Modèle de mesure utilisant les données image.....	106
5.2.3.1 Modèle de mesures image	106
5.2.3.2 Modèle de mesures radar.....	107
5.2.4 TBD multi-cible à modèle multiple (Multiple Mode Multiple Target TBD)	108
5.2.4.1 Densité à posteriori pour l'algorithme multi-cible à model multiple	108
5.2.4.2 La fonction de vraisemblance pour les mesures image	109
5.2.4.3 La fonction de vraisemblance pour les mesures radar.....	110
5.2.4.4 La prédiction de l'algorithme MM-MT-TBDF	110
5.2.4.5 Calcul des FDP conjointe de mélange des poids dans MM-MT-TBDF.....	111
5.2.4.6 Calcul des modes de probabilités pour l'algorithme MM-MT-TBDF	111
5.2.5 Implémentation de filtre particulière pour l'algorithme MM-MT-TBDF	112
5.2.5.1 L'Algorithme MM-MT-TBDF-PF	113
5.3 Simulation et commentaires de l'algorithme MM-MT-TBDF-PF (les mesures Images)	116
5.4 Simulation et commentaires de l'algorithme MM-MT-TBDF-PF (les mesures radar)	117
5.5 Conclusion.....	119

Ce dernier chapitre, présente la méthode Track-Before-Detect multi-cible permettant de suivre un nombre variable de cibles en estimant les états cibles sous toutes les combinaisons d'existence possibles. On a utilisé l'algorithme MM-MT-TBD-PF pour deux types des données mesures et deux types de trajectoires. Et nous présentons les résultats et les commentaires des simulations effectuées.

5.1 Introduction

L'algorithme de filtre (TBD) track before detect détaillé dans le chapitre précédent a été étendu pour suivre plusieurs cibles [44], Cependant, cette méthode a été utilisée pour le cas d'un nombre fixe et limité de cibles. La dimension de vecteur d'Etat dans cette méthode ne tient pas compte un nombre variable de cibles, et il ne couvre pas entièrement l'incertitude sur le nombre réel des cibles existantes. Récemment, une approche basée sur les RFS, le filtre Bernoulli multiple étiqueté a été utilisé pour suivre plusieurs cibles sous à faible rapport signal sur bruit (RSB) [125].

Dans ce chapitre, on donne un nombre connu des cibles, nous utilisons un autre algorithme qui généralise le TBDF récursif [126] pour suivre un nombre variable de cibles en faible RSB [127][49], sans aucune nécessité d'une étape de gestion de piste explicite. Dans le cas multi-cible différents modes correspondent au nombre de combinaisons des cibles qui peuvent être présentes dans le champ de surveillance. Le nouvel algorithme MM-MT-TBD [49] (Multiple-Mode Multiple Targets Track-Before-Detect) est basé sur l'estimation de la densité de probabilité à posteriori des états cibles sous différents modes afin de considérer toutes les combinaisons possibles d'existence de cibles à chaque instant. Nous implémentons le filtre particulière dans l'algorithme MM-MT-TBD de manière récursive pour incorporer des modèles de non-linéaire/non gaussien. La performance de l'algorithme MM-MT-TBD-PF est démontrée à l'aide d'un exemple simulé de deux cibles pour la mesure d'image et la mesure radar.

5.2 L'approche TBD multi-cible

5.2.1 Le Modèle d'état multi-cibles

Nous considérons le problème de poursuite multi-cibles avec un nombre maximum de \mathcal{L} cibles. Nous définissons le vecteur d'état correspondant à la $\ell^{\text{ème}}$ cible, $\ell = 1, \dots, \mathcal{L}$ à l'instant k comme suit [49]:

$$\mathbf{x}_{k,\ell} = [x_{k,\ell} \quad \dot{x}_{k,\ell} \quad y_{k,\ell} \quad \dot{y}_{k,\ell} \quad I_{k,\ell}]^T \quad (5.1)$$

Où $(x_{k,\ell}, y_{k,\ell}), (\dot{x}_{k,\ell}, \dot{y}_{k,\ell})$ et $I_{k,\ell}$ sont la position et la vitesse en 2-D, et le niveau d'intensité de la surface équivalente radar (SER) (ou est le niveau d'intensité de mesure), respectivement à l'instant k pour la $\ell^{\text{ème}}$ cible. Ce modèle d'état multi-cible tient compte du fait que toutes les cibles ne sont pas présentes à chaque instant. En particulier, à tout moment, les cibles peuvent entrer, sortir ou rester dans le champ de surveillance. Le nombre total de combinaisons ou modes d'existence de cibles possibles est donné par $M = 2^{\mathcal{L}}$. Ce nombre prend en considération le cas d'absence de toutes les cibles (aucune cible n'est présente), le cas de présence de toutes les cibles et toutes les combinaisons possibles de $\mathcal{L} - 1, \mathcal{L} - 2, \dots, 1$ cibles présentes. Le mode $i = 1$ suppose qu'aucune cible n'est présente et le mode $i = M$ suppose que toutes les \mathcal{L} cibles sont présentes. Sachant que l'ordre dans lequel les cibles apparaissent dans le champ de surveillance n'est pas important. Nous introduisons une variable d'indicateur de présence de cible binaire $C_p^i \in \{0,1\}, i = 1, \dots, M$, avec 1 (ou 0) si la $\ell^{\text{ème}}$ cible est présente (ou non) dans

le i th mode. Un exemple simple avec $M = 4$ modes pour deux cibles ($\mathcal{L} = 2$) est illustré dans la figure suivante (5-1).

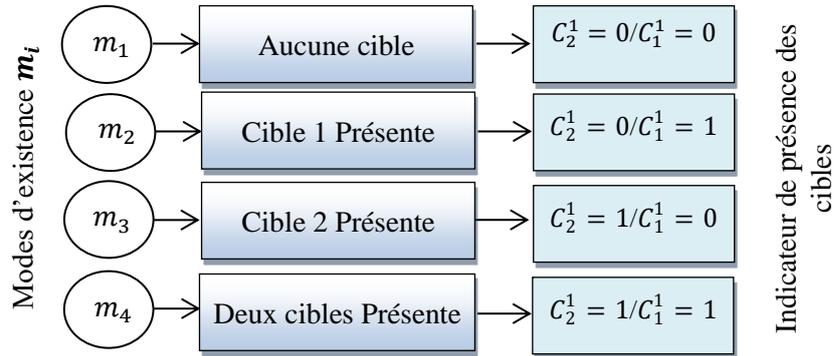


Figure 5-1 Indicateur de présence de cible pour $\mathcal{L} = 2$ cibles ($M = 4$ Modes)

Dans cette méthode, nous suivons l'évolution de toutes les combinaisons des cibles possibles et estimons la fonction de densité de probabilité (PDF) a posteriori conjoint du vecteur d'état correspondant à toutes les combinaisons. La dimension du vecteur d'état est déterminée par le nombre de cibles possibles \mathcal{L}_i dans le i th mode. Le vecteur d'état de chaque mode à l'instant k est exprimé par $x_k^{[i]}, i = 2, \dots, M$ pour prendre en compte le nombre variable des cibles et les modifications qui en résultent dans la dimension du vecteur d'état multi-cibles. Par exemple, le vecteur d'état multi-cible pour le M th mode est $x_k^{[M]} = [x_{k,1}^T \ x_{k,2}^T \ \dots \ x_{k,N_\ell}^T]^T$ car toutes les \mathcal{L} cibles sont présentes dans ce mode. Pour tous les autres modes le vecteur d'état est défini de $x_k^{[M]}$ comme $x_k^{[i]} = P_{M \rightarrow i} x_k^{[M]}$, où la matrice de projection de dimension $(5N_{\ell i} \times 5N_\ell)$ est définie par

$$P_{M \rightarrow i} = [e_{J^{[i]}(1)} \ \dots \ \dots \ e_{J^{[i]}(\mathcal{L}_i)}]^T \otimes I_5 \quad (5.2)$$

où $J^{[i]}$ est l'ensemble de toutes les cibles supposées présentes dans le mode i , e_n est le vecteur binaire de dimension $(\mathcal{L} \times 1)$ dont les éléments sont nuls sauf le nième élément mis à un, I_5 est la matrice identité (5×5) , et \otimes est le produit de Kronecker. Par exemple, avec $M = 4$ modes pour $\mathcal{L} = 2$ cibles, $P_{4 \rightarrow 2}$ est la matrice de projection pour obtenir le vecteur d'état de mode qui ne contient que la cible 1 (m_2 dans la figure 5-1) est donné par

$$P_{4 \rightarrow 2} = [1 \ 0] \otimes I_5 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (5.3)$$

Le vecteur d'état pour le mode $i = 2$ est donné par

$$x_k^{[2]} = P_{4 \rightarrow 2} x_k^{[4]} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} x_{k,1} \\ x_{k,2} \end{bmatrix} \quad (5.4)$$

Le modèle dynamique d'état multi-cible pour chaque mode est écrit comme suit

$$\mathbf{x}_k^{[i]} = F^{[i]} \mathbf{x}_{k-1}^{[i]} + \mathbf{v}_k^{[i]} \quad (5.5)$$

où $\mathbf{v}_k^{[i]} = P_{M \rightarrow i} [v_{k,1}^T \ v_{k,2}^T \ \dots \ v_{k,N_\ell}^T]$ et $v_{k,\ell}$ est un processus aléatoire d'erreur de modélisation avec une matrice de covariance Q_ℓ . Supposant le modèle dynamique de mouvement pour toutes les cibles, alors $F^{[i]} = F \otimes I_{\mathcal{L}_i}$.

5.2.2 Matrice de transition

L'incertitude de la présence ou d'absence de la cible dans l'espace de mesure est modélisée comme un processus aléatoire avec une chaîne de Markov à deux états de premier ordre[15]. $P_{b,\ell}$, $P_{d,\ell}$ sont les probabilités de transition de la $\ell^{\text{ème}}$ cible entre et quitte le champ de surveillance, respectivement. Ainsi que, les deux autres probabilités de cette chaîne de Markov sont la probabilité que le la $\ell^{\text{ème}}$ cible reste dans le champ ($1 - P_{d,\ell}$) et la probabilité que le la $\ell^{\text{ème}}$ cible quitte le champ de surveillance ($1 - P_{b,\ell}$). La matrice de transition pour le processus de Markov correspondant à la $\ell^{\text{ème}}$ cible est donnée par

$$\Pi_\ell = \begin{bmatrix} 1 - P_{b,\ell} & P_{b,\ell} \\ P_{d,\ell} & 1 - P_{d,\ell} \end{bmatrix} \quad (5.6)$$

La variable m_k (mode) est modélisée comme un processus aléatoire discret suivant une chaîne de Markov du premier ordre de M -état. Plus précisément, la probabilité que le mode passe du mode j à l'instant $k - 1$ au mode i à l'instant k est donnée par

$$\Pi_{ij} = Pr\{m_{k+1} = i | m_k = j\}, i, j = 1, \dots, M \quad (5.7)$$

Pour un nombre donné de cibles \mathcal{L} , le mode générale de la matrice de transition est donné par :

$$\Pi = \Pi_1 \otimes \Pi_2 \dots \otimes \Pi_{N_\ell} \quad (5.8)$$

Où \otimes est le produit Kronecker. Pour un exemple simple de deux cibles $\mathcal{L} = 2$ avec $M = 4$ modes. La matrice de transition de mode correspondant en supposant que les deux cibles ont la même matrice de transition $\Pi_1 = \Pi_2$ et $P_{b1} = P_{b2} = P_b$ et $P_{d1} = P_{d2} = P_d$ est donnée par :

$$\Pi = \begin{bmatrix} (1 - P_b)^2 & P_b(1 - P_b) & (1 - P_b)P_b & P_b^2 \\ P_d(1 - P_b) & (1 - P_d)(1 - P_b) & P_d P_b & (1 - P_d)P_b \\ (1 - P_b)P_d & P_b P_d & (1 - P_d)(1 - P_b) & P_b(1 - P_d) \\ P_d^2 & (1 - P_d)P_d & P_d(1 - P_d) & (1 - P_d)^2 \end{bmatrix} \quad (5.9)$$

5.2.3 Modèle de mesure utilisant les données image

5.2.3.1 Modèle de mesures image

On utilise les mêmes mesures de chapitre précédent mais pour plusieurs cible ponctuelles. Le modèle de mesures image multi-cibles est donné par :

$$z_k^{(i,j)} = \begin{cases} \sum_{\ell=0}^{N_\ell} C_\ell^i h_k^{(a,b)}(x_{k,\ell}^{[i]}) + \omega_k^{(a,b)}, & \text{for } i = 2, \dots, M \\ \omega_k^{(a,b)}, & \text{for } i = 1 \end{cases} \quad (5.10)$$

$$\text{Où} \quad h_k^{(a,b)}(x_k^{(\ell)}) = \frac{\Delta_x \Delta_y I_k^\ell}{2\pi \Sigma^2} \exp \left[-\frac{(a\Delta_x - x_k^\ell)^2 + (b\Delta_y - y_k^\ell)^2}{2\Sigma^2} \right] \quad (5.11)$$

est la fonction de mesure et représente contribution de l'intensité de la cible ℓ et Σ est un paramètre connu qui contrôle le flou introduit par le capteur et $x_{k,\ell}^{[i]}$ est le vecteur d'état de la $\ell^{\text{ième}}$ cible en mode i . Le bruit de mesure $\omega_k^{(a,b)}$ dans chaque pixel est supposé être indépendant et gaussien distribué avec une variance r .

Le vecteur de mesures est donné par

$$z_k = [z_k^{(1,1)} \quad z_k^{(1,2)} \quad \dots \quad z_k^{(1,b)} \quad z_k^{(2,1)} \quad z_k^{(2,2)} \quad \dots \quad z_k^{(2,b)} \quad \dots \quad z_k^{(a,1)} \quad \dots \quad z_k^{(a,b)}]^T \quad (5.12)$$

Et l'ensemble de toutes les mesures jusqu'à l'instant k est donné par :

$$z_{1:k} = \{z_1, z_2, \dots, z_k\} \quad (5.13)$$

5.2.3.2 Modèle de mesures radar

Comme dans le cas de mesures radar mono-cible de chapitre précédent (Chapitre 4). Nous supposons que le cadre de mesure est constituée de données prétraitées provenant d'un système radar pour différentes case de portées $r_{k,\ell}$, vitesse angulaire $\dot{r}_{k,\ell}$, et angle azimutal $\theta_{k,\ell}$ pour la $\ell^{\text{ième}}$ cible. Les différents paramètres associée au vecteur d'état $(r_k, \dot{r}_k, \theta_k)$ sont déjà donnée par la formule (4.11). Le modèle de mesures radar multi-cibles est donné par l'équation suivante :

$$z_k^{(a,b,c)} = \begin{cases} \sum_{\ell=1}^{N_\ell} C_\ell^i h_k^{(a,b,c)}(x_{k,\ell}^{[i]}) + \omega_k^{(a,b,c)}, & \text{for } i = 2, \dots, M \\ \omega_k^{(a,b,c)}, & \text{for } i = 1 \end{cases} \quad (5.14)$$

où C_ℓ^i est un indicateur de présence de la $\ell^{\text{ième}}$ cible dans le $i^{\text{ième}}$ mode, et

$$h_k^{(a,b,c)}(x_k^{[i]}) = A_k \exp \left(-\left(\frac{a\Delta_r - r_{k,\ell}}{2\sigma_r}\right)^2 - \left(\frac{b\Delta_{\dot{r}} - \dot{r}_{k,\ell}}{2\sigma_{\dot{r}}}\right)^2 - \left(\frac{c\Delta_\theta - \theta_{k,\ell}}{2\sigma_\theta}\right)^2 \right) \quad (5.15)$$

où $A_k = \frac{\Delta_r \Delta_{\dot{r}} \Delta_\theta I_{k,\ell}}{(2\pi)^{3/2} \sigma_r \sigma_{\dot{r}} \sigma_\theta}$ est l'amplitude normalisée, $I_{k,\ell}$ est l'intensité du signal reçu de la $\ell^{\text{ième}}$ cible et $\sigma_r, \sigma_{\dot{r}}, \sigma_\theta$ sont des paramètres connus qui contrôlent l'étalement introduit par le système radar, (la cellule (i, j, ℓ) donné en chapitre 2 est remplacé par la cellule (a, b, c) . Les bruit de mesure $\omega_k^{(a,b,c)}$ dans l'équation (5.17) sont supposés gaussiens avec une moyenne nulle et une variance v_k . Le vecteur de mesure global est donné par

$$z_k = [z_k^{(1,1,1)} \quad \dots \quad z_k^{(1,1,N_\theta)} \quad \dots \quad z_k^{(1,N_{\dot{r}},N_\theta)} \quad \dots \quad z_{k,S}^{(1,N_{\dot{r}},N_\theta)} \quad \dots \quad z_{k,S}^{(N_r,N_{\dot{r}},N_\theta)}]^T \quad (5.16)$$

Et l'ensemble de toutes les mesures jusqu'à l'instant k est donné par :

$$z_{1:k} = \{z_1, z_2, \dots, z_k\} \quad (5.17)$$

5.2.4 TBD multi-cible à modèle multiple (Multiple Mode Multiple Target TBD)

5.2.4.1 Densité à posteriori pour l'algorithme multi-cible à model multiple

Contrairement au TBDF mono-cible dans [126], nous estimons deux ensembles de fonction de densité de probabilité (FDP) conditionnels. Le premier ensemble de FDPs correspond aux FDPs conjointe a posteriori conditionnées par l'état de mode à l'instant $(k - 1)$ et k . Le deuxième ensemble de densités de probabilité est obtenu sous la forme d'un mélange pondéré d'un sous-ensemble du premier ensemble de densités de probabilité conjointe ayant la même dimension de vecteur d'état.

Plus précisément, étant donné les modèles d'état et de mesure et le PDF à posteriori $p(x_{k-1}^{[i]} | z_{1:k-1})$, $\forall i$, au temps $k - 1$, le MM-MT-TBDF estime le PDF à posteriori $p(x_{k,\ell} | z_{1:k})$ à l'instant k et la probabilité d'existence cible correspondante $P_r(e_{k,\ell} | z_{1:k})$, où $e_{k,\ell}$ est l'événement correspondant à la présence de la $\ell^{\text{ième}}$ cible. Nous supposons que la probabilité du mode initial, $P_r(m_0 = i | z_0)$, $i = 1, \dots, M$ est connue a priori. Si cette valeur n'est pas connue, on peut supposer qu'aucune cible n'est initialement présente, c'est-à-dire que $P_r(m_0 = i | z_0) = 0$, pour $i = 2, \dots, M$, et $P_r(m_0 = 1 | z_0) = 1$.

Comme les différents modes sont mutuellement exclusifs, $P_r(m_k = i, m_k = j | z_{1:k}) = 0, \forall i \neq j$, la fonction de densité de probabilité à posteriori (FDP) peut s'écrire comme suit

$$p(x_{k,\ell} | z_{1:k}) = \sum_{i=1}^M C_{\ell}^i p(x_{k,\ell}^{[i]}, m_k = i | z_{1:k}) \quad (5.18)$$

Où $x_{k,\ell}^{[i]}$ est le vecteur d'état correspondant à la $\ell^{\text{ième}}$ cible présente en mode i .

Les fonctions de densité de probabilité marginales sont obtenues en marginalisant la FDP conjointe qui s'écrit comme suit

$$p(x_k^{[i]}, m_k = i | z_{1:k}) = p(x_k^{[i]} | m_k = i, z_{1:k}) P_r(m_k = i | z_{1:k}) \quad (5.19)$$

Où $P_{k,i} \triangleq P_r(m_k = i | Z_k)$, $i = 2, \dots, M$ est de probabilité a posteriori de mode. En utilisant une solution bayésienne pour plusieurs modèles de commutation, la fonction de densité de probabilité (PDF) de l'état de la cible en fonction d'un mode particulier est obtenue en pondérant les M fonctions de densité.

$$\begin{aligned} p(x_k^{[i]} | m_k = i, z_{1:k}) &= \sum_{j=1}^M p(x_k^{[i]} | m_{k-1} = j, m_k = i, z_{1:k}) P_r(m_{k-1} = j | m_k = i, z_{1:k}) \\ &= \sum_{j=1}^M p_{j,i}(x_k^{[i]} | z_{1:k}) P_r(m_{k-1} = j | m_k = i, z_{1:k}) \end{aligned} \quad (5.20)$$

En remplaçant l'équation (5.17) par $p_{j,i}(x_k^{[i]} | z_{1:k})$. En utilisant la règle de Bayes, la FDP d'état conditionné en mode mentionné ci-dessus peut être étendu comme suit

$$p_{j,i}(x_k^{[i]} | z_{1:k}) = \frac{p(z_k | m_{k-1} = j, m_k = i, x_k^{[i]}) p(x_k^{[i]} | m_{k-1} = j, m_k = i, z_{1:k-1})}{p(z_k | m_{k-1} = j, m_k = i, z_{1:k-1})}$$

$$= \frac{p_{j,i}(z_k | x_k^{[i]}) p_{j,i}(x_k^{[i]} | z_{1:k-1})}{p_{j,i}(z_k | z_{1:k-1})} \quad (5.21)$$

Nous remplaçons $p(z_k | m_{k-1} = j, m_k = i, x_k^{[i]})$, $p(x_k^{[i]} | m_{k-1} = j, m_k = i, z_{1:k-1})$ et $p(z_k | m_{k-1} = j, m_k = i, z_{1:k-1})$ par $p_{j,i}(z_k | x_k^{[i]})$, $p_{j,i}(x_k^{[i]} | z_{1:k-1})$, and $p_{j,i}(z_k | z_{1:k-1})$, respectivement. Nous divisons le numérateur et le dénominateur par $p(z_k | m_k = 0)$, ce qui suppose qu'aucune cible n'est présente, alors nous pouvons exprimer la FDP à posteriori en fonction des rapports de vraisemblance,

$$L_{j,i}(z_k | x_k^{[i]}) = \frac{p_{j,i}(z_k | x_k^{[i]})}{p(z_k | m_k = 0)} \quad (5.22)$$

$$L_{j,i}(z_k | z_{1:k-1}) = \frac{p_{j,i}(z_k | z_{1:k-1})}{p(z_k | m_k = 0)} \quad (5.23)$$

comme suit

$$p_{j,i}(x_k^{[i]} | z_{1:k}) = \frac{L_{j,i}(z_k | x_k^{[i]}) p_{j,i}(x_k^{[i]} | z_{1:k-1})}{L_{j,i}(z_k | z_{1:k-1})} \quad (5.24)$$

où le dénominateur est le terme de normalisation.

$$L_{j,i}(z_k | z_{1:k-1}) = \int L_{j,i}(z_k | x_k^{[i]}) p_{j,i}(x_k^{[i]} | z_{1:k-1}) dx_k^{[i]} \quad (5.25)$$

Et $L_{j,i}(z_k | x_k^{[i]})$ est la fonction de vraisemblance commune conditionnée par les modes précédent et actuel.

5.2.4.2 La fonction de vraisemblance pour les mesures image

Le bruit de mesure est supposé indépendant entre les pixels, on peut écrire la fonction de vraisemblance conjointe comme suit

$$p(z_k | x_k^{[i]}) = \begin{cases} \prod_{a=1}^{N_x} \prod_{b=1}^{N_y} \mathcal{N}(z_k^{(a,b)}; \Upsilon_k^{(a,b)}(x_k^{[i]}), v_k), & m_{k-1} = 1 \dots M, m_k = 2 \dots M \\ \prod_{a=1}^{N_x} \prod_{b=1}^{N_y} \mathcal{N}(z_k^{(a,b)}; 0, v_k), & m_k = 1 \end{cases} \quad (5.26)$$

Avec $\Upsilon_k^{(a,b)}(x_k^{[i]}) = \sum_{\ell=1}^{N_\ell} C_\ell^i h_k^{(a,b)}(x_k^{[i]})$ est la contribution cumulative au pixel (a, b) de toutes les cibles en mode i et $h_k^{(a,b)}(x_k^{[i]})$ est définie dans l'équation (5.12).

Le rapport de vraisemblance dans l'équation (5.24) peut s'écrire comme suit

$$L_{j,i}(z_k | x_k^{[i]}) = \begin{cases} \frac{\prod_{a=1}^{N_x} \prod_{b=1}^{N_y} \mathcal{N}(z_k^{(a,b)}; \Upsilon_k^{(a,b)}(x_k^{[i]}), v_k)}{\prod_{a=1}^{N_x} \prod_{b=1}^{N_y} \mathcal{N}(z_k^{(a,b)}; 0, v_k)}, & m_{k-1} = 1 \dots M, m_k = 2 \dots M \\ 1, & m_k = 1 \end{cases} \quad (5.27)$$

$$= \begin{cases} \prod_{a \in \beta_x(x_k^{[i]})} \prod_{b \in \beta_x(x_k^{[i]})} l(z_k^{(a,b)} | x_k^{[i]}), & m_{k-1} = 1 \dots M, m_k = 2 \dots M \\ 1, & m_k = 1 \end{cases} \quad (5.28)$$

où $\beta_x(x_k^{[i]})$ et $\beta_y(x_k^{[i]})$ sont l'ensemble des pixels dans le voisinage des cellules affecté par la présence de cibles en mode i sont présentes. Le rapport de vraisemblance est donné par

$$l(z_k^{(a,b)} | x_k^{[i]}) \triangleq \exp \left\{ - \frac{\gamma_k^{(a,b)}(x_k^{[i]}) (\gamma_k^{(a,b)}(x_k^{[i]}) - 2z_k^{(a,b)})}{2v_k} \right\} \quad (5.29)$$

5.2.4.3 La fonction de vraisemblance pour les mesures radar

Puisque l'on suppose que le bruit de mesure est indépendant entre les cellules (bins), on peut écrire la fonction de vraisemblance conjointe comme suit

$$p(z_k | x_k^{[i]}) = \begin{cases} \prod_{a=1}^{N_r} \prod_{b=1}^{N_r} \prod_{c=1}^{N_\theta} \mathcal{N}(z_k^{(a,b,c)}; \gamma_k^{(a,b,c)}(x_k^{[i]}), v_k), & m_{k-1} = 1 \dots M, m_k = 2 \dots M \\ \prod_{a=1}^{N_r} \prod_{b=1}^{N_r} \prod_{c=1}^{N_\theta} \mathcal{N}(z_k^{(a,b,c)}; 0, w_k), & m_k = 1 \end{cases} \quad (5.30)$$

Avec $\gamma_k^{(a,b,c)}(x_k^{[i]}) = \sum_{\ell=1}^{N_\ell} C_\ell^i h_k^{(a,b,c)}(x_{k,\ell}^{[i]})$ est la contribution cumulative au cellule (a, b, c) de toutes les cibles en mode i et $h_k^{(a,b,c)}(x_{k,\ell}^{[i]})$ est définie dans l'équation (5.15). Afin de réduire la charge de calcul, seuls les cellules situés à proximité des cibles existantes sont utilisés. La fonction de vraisemblance dans l'équation (5.23) peut être écrite comme suit

$$L_{j,i}(z_k | x_k^{[i]}) = \begin{cases} \prod_{a \in \beta_r(x_k^{[i]})} \prod_{b \in \beta_{\dot{r}}(x_k^{[i]})} \prod_{c \in \beta_\theta(x_k^{[i]})} \lambda(z_k^{(a,b,c)} | x_k^{[i]}), & m_{k-1} = \forall M, m_k = 2 \dots M \\ 1, & m_k = 1 \end{cases} \quad (5.31)$$

où $\beta_r(x_k^{[i]})$, $\beta_{\dot{r}}(x_k^{[i]})$ et $\beta_\theta(x_k^{[i]})$ sont l'ensemble toutes les cellules de la portée, la vitesse angulaire et d'angle azimutal, respectivement, qui se trouvent dans le voisinage des cellules affecté par la présence de cibles en mode i sont présentes. Le rapport de vraisemblance est donné par

$$\lambda(z_k^{(a,b,c)} | x_k^{[i]}) \triangleq \exp \left\{ - \frac{\gamma_k^{(a,b,c)}(x_k^{[i]}) (\gamma_k^{(a,b,c)}(x_k^{[i]}) - 2z_k^{(a,b,c)})}{2v_k} \right\} \quad (5.32)$$

5.2.4.4 La prédiction de l'algorithme MM-MT-TBDF

Dans le cadre bayésien récursif, étant donné la FDP en mode conditionné à postériori, nous devons d'abord prédire le PDF du vecteur d'état à l'instant k conditionné sur les modes $m_{k-1} = j$ et $m_k = i$. La FDP d'état prédit conditionné sur les modes précédent et courant est alors donné par

$$p_{j,i}(x_k^{[i]} | z_{1:k-1}) = \int p_{j,i}(x_k^{[i]} | y_{k-1}^{[i]}, z_{1:k-1}) p(y_{k-1}^{[i]} | m_{k-1} = j, z_{1:k-1}) dy_{k-1}^{[i]} \quad (4.40) \quad (5.33)$$

Où $y_{k-1}^{[i]} = P_{j \rightarrow i} x_{k-1}^{[j]}$ est la transformation de vecteur d'état de $j^{\text{ième}}$ mode au $i^{\text{ième}}$ mode et $P_{j \rightarrow i}$ est la matrice de projection[128].

5.2.4.5 Calcul des FDP conjointe de mélange des poids dans MM-MT-TBDF

Utilisant la règle de Bayes, on peut écrire les poids comme suit

$$\begin{aligned} P_r(m_{k-1} = j | m_k = i, z_{1:k}) &= \frac{p_{j,i}(z_k | z_{1:k-1}) P_r(m_{k-1} = j | m_k = i, z_{1:k-1})}{p(z_k | m_k = i, z_{1:k-1})} \\ &= \frac{p_{j,i}(z_k | z_{1:k-1}) \Pi_{j,i} P_{k-1,j}}{p(z_k | m_k = i, z_{1:k-1}) P_r(m_k = i | z_{1:k-1})} \end{aligned} \quad (5.34)$$

où la probabilité de transition de mode est calculée par: $\Pi_{\ell,m} = P_r(m_{k,m} | m_{k-1}, z_{1:k-1})$

Les poids peuvent s'exprimer en fonction du rapport de vraisemblance comme suit

$$P_r(m_{k-1} = j | m_k = i, z_{1:k}) = \frac{L_{j,i}(z_k | z_{1:k-1}) \Pi_{j,i} P_{k-1,j}}{L(z_k | m_k = i, z_{1:k-1}) P_r(m_k = i | z_{1:k-1})} \quad (5.35)$$

5.2.4.6 Calcul des modes de probabilités pour l'algorithme MM-MT-TBDF

On peut calculer la probabilité du mode a posteriori $P_{k,i}$ comme suit

$$P_{k,i} = \sum_{j=1}^M P_r(m_k = i | m_{k-1} = j, z_{1:k}) P_r(m_{k-1} = j | z_{1:k}) \quad (5.36)$$

Utilisant la règle de Bayes, on peut écrire le premier terme de (5.38) comme suit :

$$P_r(m_k = i | m_{k-1} = j, z_{1:k}) = \frac{p_{j,i}(z_k | z_{1:k-1}) \Pi_{j,i} P_{k-1,j}}{p(z_k | z_{1:k-1}) P_r(m_{k-1} = j | z_{1:k})} \quad (5.37)$$

Lorsqu'on remplace par (5.39) dans (5.38), on obtient

$$P_{k,i} = \frac{\sum_{j=1}^M \Lambda_{j,i} \Pi_{j,i} P_{k-1,j}}{\sum_{j=1}^M [\Pi_{j,i} P_{k-1,j} + \sum_{i'=2}^M \Lambda_{j,i'} \Pi_{j,i'} P_{k-1,j}]} \quad (5.38)$$

Où $\Lambda_{j,i} \triangleq L_{j,i}(z_k | z_{1:k-1})$ et $P_{k-1,j}$ est la probabilité à postérieure du mode à l'instant $k - 1$.

Les étapes de l'algorithme *MM-MT-TBDF* est donnée par la table (5-1).

Initialiser la fonction de distribution $p\left(x_0^{[i]} \mid m_0 = i, z_0\right)$ et les modes de probabilités $P_{0,i}$, $i = 2, \dots, M$.

Pour $k = 1: K$ faire

étape 1 : Prédiction de la fonction de distribution d'état $p_{j,i}\left(x_k^{[i]} \mid z_{1:k-1}\right)$, conditionnée par le

mode j à l'instant $k - 1$ et le mode i à l'instant k , en utilisant l'équation (5.33)

pour

$j = 1, \dots, M$ et $i = 1, \dots, M$

étape 2 : Calculer la fonction de vraisemblance conditionnée au mode j et i , en utilisant les équations (5.28) ou (5.31)

étape 3 : Mise à jour de la fonction de densité d'état a posteriori $p_{j,i}\left(x_k^{[i]} \mid z_{1:k}\right)$, conditionnée

par le mode j à l'instant $k - 1$ et le mode i à l'instant k , utilisant l'équation (5.24)

étape 4 : Calculer les probabilités de mélange $P_r(m_{k-1} = j \mid m_k = i, z_{1:k})$, utilisant l'équation

(5.24).

étape 5 : Calculer les probabilités a posteriori des modes $P_{k,i}$ utilisant l'équation (5.37).

étape 6 : Calculer la densité a posteriori de l'état cible conditionnée par un mode

$p\left(x_k^{[i]} \mid m_k = i, Z_k\right)$, utilisant l'équation (5.19).

étape 7 : Marginaliser la densité a posteriori de l'état cible à l'étape 6 pour obtenir la densité a

posteriori des cibles individuelles en mode i .

étape 8 : Combiner les fonctions de densité marginale de tous les modes en utilisant

l'équation (5.18) pour obtenir la fonction de densité marginale de la ℓ ème cible.

Fin Pour

Table 5-1 Les étapes de l'algorithme MM-MT-TBDF pour la poursuite multi-cibles

5.2.5 Implémentation de filtre particulaire pour l'algorithme MM-MT-TBDF

Dans la section précédente, nous avons dérivé la solution bayésienne de l'algorithme MM-MT-TBDF. Lorsque les modèles d'état et de mesure sont non linéaires et non gaussiens, le TBDF doit être résolu en utilisant des techniques séquentielles de Monte Carlo (SMC) telles que le filtrage particulaire. L'implémentation basée sur le filtre particulaire (MM-MT-TBDF-PF) utilise trois couches PF. La première couche c'est une approximation de la FDP a posteriori des états cibles $x_k^{[i]}$, conditionnée par le mode i au à l'instant k et le mode j à l'instant $k - 1$. Cette approximation est donnée par

$$p\left(x_k^{[i]} \mid m_{k-1} = j, m_k = i, z_{1:k}\right) \approx \sum_{n=1}^{N_{j,i}} \phi_k^{(j,i,n)} \delta\left(x_k^{[i]} - x_k^{(j,i,n)}\right) \quad (5.39)$$

La deuxième couche c'est une approximation de mode de FDP a posteriori conditionné. Cette approximation est donnée par

$$p\left(x_k^{[i]} \mid m_k = i, z_{1:k}\right) \approx \sum_{n=1}^{N_i} \chi_k^{(i,n)} \delta\left(x_k^{[i]} - x_k^{(i,n)}\right) \quad (5.40)$$

La dernière couche approxime la FDP a posteriori des cibles individuelles comme suit

$$p\left(x_{k,\ell} \mid Z_k\right) = \sum_{n=1}^{N_\ell} \omega_{k,\ell}^{(n)} \delta\left(x_{k,\ell} - x_{k,\ell}^{(n)}\right) \quad (5.41)$$

5.2.5.1 L'Algorithme MM-MT-TBDF-PF

Nous commençons cet algorithme par l'initialisation des particules $x_0^{(i,n)}$ et les poids $\chi_0^{(i,n)}$, $i = 2, \dots, M$ pour tous les modes. A l'instant k , $N_{j,i}$ des nouvelles particules sont générées pour approximer la densité $p\left(x_k^{[i]} \mid m_{k-1} = j, m_{k-1} = i, z_{1:k}\right)$, pour tous les i et j .

Les échantillons sont générés en fonction de la présence ou l'absence d'une cible particulière dans le mode précédent.

Il y a trois cas possibles.

- *La cible entre dans la région de surveillance* : Si une cible en mode i n'était pas présente en mode j , alors cette cible est considérée comme une entrante dans le champ de surveillance à l'instant k et les particules sont générées sur la base d'une distribution connue a priori pour une nouvelle cible. Si aucune information a priori sur une nouvelle cible n'est disponible, on peut supposer une distribution uniforme.
- *Cible quitte le champ de surveillance* : Une cible a quitté le champ de surveillance si elle est présente en mode j et absente i . Les particules correspondant à cette cible à l'instant k sont ignorées.
- *Cible reste dans le champs de surveillance* : Si une cible est déjà présente dans le le champ de surveillance au mode j et reste présente au mode i , la mise à jour des particules de $p\left(x_k^{[i]} \mid z_{1:k}\right)$ est réalisé par l'équation (5.5).

Enfin, les états de toutes les cibles présentes en mode i sont concaténés pour approximer la $p_{j,i}\left(x_k^{[i]} \mid z_{1:k-1}\right)$.

Les poids des particules $N_{j,i}$ sont calculés utilisant la fonction de vraisemblance conjointe conditionnée dans le mode de l'équation (5.31) :

$$\tilde{\phi}_k^{(j,i,n)} \propto L\left(z_k \mid x_k^{(j,i,n)}, m_{k-1} = j, m_k = i\right) \prod_{\ell=1}^{\mathcal{L}_i} \frac{p\left(x_{k,\ell}^{(j,i,n)} \mid y_{k-1,\ell}^{(i,n)}, z_{1:k}\right)}{q\left(x_{k,\ell}^{(j,i,n)} \mid y_{k-1,\ell}^{(i,n)}, z_{1:k}\right)} \quad (5.42)$$

où \mathcal{L}_i est le nombre de cibles en mode i . Les poids sont normalisés par

$$\Lambda'_{j,i} = \sum_{n=1}^{N_{j,i}} \tilde{\phi}_k^{(j,i,n)} \quad (5.43)$$

pour obtenir $\phi_k^{(j,i,n)} = \tilde{\phi}_k^{(j,i,n)} / \Lambda'_{j,i}$, et $\Lambda'_{j,i}$ est l'approximation particulaire de $\Lambda_{j,i}$ dans les équations (5.25) et (5.38). Étant donné la probabilité de mode initiale $P_{0,i}$, pour tout i , les probabilités de mélange de l'équation (5.35) sont ensuite calculées comme suit:

$$P_r(m_{k-1} = j | m_k = i, z_{1:k}) = \frac{\Lambda'_{j,i} \Omega_{j,i} P_{k-1,j}}{\sum_{j'=1}^M \Lambda'_{j',i} \Omega_{j',i} P_{k-1,j'}} \quad (5.44)$$

L'approximation de FDP de mode conditionné dans l'équation (5.44) est donné par :

$$p(x_k^{[i]} | m_k = i, z_{1:k}) \approx \sum_{j=0}^{M-1} \sum_{n=1}^{N_{j,i}} P_r(j, i) \phi_k^{(j,i,n)} \delta(x_k^{[i]} - x_k^{(j,i,n)}) \quad (5.45)$$

Le nombre des particules représentant $p(x_k^{[i]} | m_k = i, z_{1:k})$ est égal à la somme des particules représentant chaque transition de mode. Afin de réduire la complexité de calcul, les poids des particules ci-dessus sont triés et les poids les plus élevés N_i avec leurs particules correspondantes sont sélectionnés. Les poids triés sont ensuite normalisés et ré-échantillonnés pour obtenir $\chi_k^{(i,n)}$. La probabilité conditionnée de mode peut ensuite approximer comme dans l'équation (5.44). Notez que les particules $x_k^{(i,n)}$ sont ré-échantillonnées pour éviter la dégénérescence de l'échantillon [14]. Le FDP marginal a posteriori conditionné en mode marginal de la $\ell^{i\text{ème}}$ cible $p(x_{k,\ell} | z_{1:k})$ est obtenu en sélectionnant des particules correspondant à cette cible particulière, à savoir:

$$p(x_k^{[i]} | m_k = i, z_{1:k}) \approx \sum_{n=1}^{N_i} \chi_k^{(i,n)} \delta(x_{k,\ell}^{[i]} - x_{k,\ell}^{(i,n)}) \quad (5.46)$$

Les probabilités de mode sont calculées à l'aide de l'équation (5.38) en substituant $\Lambda'_{j,i}$ pour $\Lambda_{j,i}$. La probabilité de mode correspondant à l'absence de cibles est obtenue en soustrayant de 1, c'est-à-dire la somme des probabilités des autres modes.

$$P_{k,0} = 1 - \sum_{i=2}^M P_{k,i} \quad (5.47)$$

Enfin, les particules correspondant à tous les modes qui incluent la $\ell^{i\text{ème}}$ cible sont combinées et pondérées en fonction de la probabilité de mode. Comme suit,

$$p(x_{k,\ell} | z_{1:k}) \approx \sum_{i=2}^M \sum_{n=1}^{N_i} C_\ell^i \chi_k^{(i,n)} \delta(x_{k,\ell}^{[i]} - x_{k,\ell}^{(i,n)}) \quad (5.48)$$

Comme mentionné ci-dessus, pendant le processus de mélange, le nombre de particules représentant $p(x_{k,\ell} | z_{1:k})$ est égal à la somme des particules représentant chaque mode. Les poids des particules ci-dessus sont triés et les N_ℓ poids les plus élevés avec leurs particules correspondantes sont sélectionnés. Les poids triés sont ensuite normalisés et ré-échantillonnés pour obtenir $\omega_{k,\ell}^{(n)}$ qui sera utilisé pour approximer $p(x_{k,\ell} | z_{1:k})$ comme dans l'équation (5.41). La probabilité d'existence de la $\ell^{i\text{ème}}$ cible est obtenue en additionnant les probabilités de mode pertinentes comme suit:

$$P_r(e_{k,\ell} | z_{1:k}) = \sum_{i=2}^M C_\ell^i P_{k,i} \quad (5.49)$$

Les étapes de l'implémentation de FP dans l'algorithme MM-MT-TBDF sont résumées dans l'algorithme de la table (5-2).

Initialiser la distribution des particules de $p(x_0^{[i]} | m_0 = i, z_0)$ et le mode probabilité $P_{0,i}, i = 2, \dots, M$

Pour $k = 1:K$ faire

Étape1 : Prédire la distribution des particules pour $p_{j,i}(x_k^{[i]} | z_{1:k-1})$, conditionné par le mode j à l'instant $k - 1$ et au mode i à l'instant k pour $j = 1, \dots, M$ et $i = 2, \dots, M$.

- Les particules des nouvelles cibles entrant dans le champ de surveillance:

$$x_{k,nb}^{(n)} \sim q(x_{k,\ell}^{(j,i,n)}), n = 1, \dots, N_{nb}, N_{nb} \gg N_{j,i}, \ell = 1, \dots, (\mathcal{L})_i$$

Calculer la fonction de vraisemblance $L(z_{1:k} | x_{k,nb}^{(n)})$

Sélectionnez $N_{j,i}$ les particules de probabilité la plus élevée et définissez-les par $x_{k,\ell}^{(j,i,n)}$

- Les particules pour les cibles restant dans le champs de surveillance:

$$x_{k,\ell}^{(j,i,n)} \sim p(x_{k,\ell}^{(j,i,n)} | y_{k-1,\ell}^{(i,n)}) n = 1, \dots, N_{j,i}, \ell = 1, \dots, (\mathcal{L})_i$$

- Concaténer les nouvelles particules pour obtenir $x_{k,\ell}^{(j,i,n)}$

Étape2 : Calculez la fonction de vraisemblance conjointe, conditionné par les modes j et i , utilisant l'équation (5.31).

Étape3 : Calculer les poids $\{\tilde{\phi}_k^{(j,i,n)}\}_{n=1}^{N_{i,j}}$ comme dans l'équation (5.43) en fonction de la fonction de densité de la proposition.

Étape4 : Calculer les poids cumulés $\Lambda'_{j,i}$ utilisant l'équation (4.25)

Étape5 : Normaliser les poids $\{\tilde{\phi}_k^{(j,i,n)}\}_{n=1}^{N_{i,j}}$

Étape6 : Calculer les probabilités de mélange $P_r(m_{k-1} = j | m_k = i, z_{1:k})$ utilisant l'équation (4.26)

Étape7 : Mise à jour la FDP a postérieure conditionnée en mode, $p(x_k^{[i]} | m_k = i, z_{1:k})$, utilisant l'équation (4.27)

Étape8 : Choisir N_i les poids les plus élevés et normalisez les poids pour obtenir $\{\chi_k^{(i,n)}\}_{n=1}^{N_i}$

Étape9 : Ré-échantillonnez les poids normalisés pour obtenir $x_k^{(i,n)}$

Étape10 : Marginaliser la FDP a postérieure pour obtenir $x_{k,\ell}^{(i,n)}, \ell = 1, \dots, \mathcal{L}_i$

Étape11 : Calculer les probabilités a postérieure du mode $P_{k,i}$ en utilisant l'équation (5.38)

Étape12 : Calculer la FDP a postérieure de l'état cible individuel $p(x_{k,\ell} | z_{1:k})$, en utilisant Équation (5.48)

Étape13 : Sélectionnez N_ℓ les poids les plus élevés et normalisez-les pour obtenir $\{\omega_{k,\ell}^{(n)}\}_{n=1}^{N_\ell}$

Étape14 : Ré-échantillonnez les poids normalisés pour obtenir $x_{k,\ell}^{(n)}, \ell = 1, \dots, N_\ell$

Étape15 : Calculer la probabilité d'existence cible à l'aide de l'équation (5.49)

Fin Pour

Table 5-2 Les étapes de l'algorithme MM-MT-TBDF-PF pour la poursuite multi-cibles

5.3 Simulation et commentaires de l'algorithme MM-MT-TBDF-PF (les mesures Images)

Nous avons implémenté l'algorithme MM-MT-TBD (un cas très simple) [129] pour suivre deux cibles ponctuelles à faible RSB avec des mesures images 2-D. Nous avons supposé un mouvement à vitesse constante (CV) et des modèles de bruit de processus gaussienne additive [9].

La matrice de transition et la covariance du bruit de modèle CV sont donnée par (4.39) et (4.40).

On considère une séquence de 30 images est générée en utilisant les paramètres $T = 1s$, $\Delta_x = \Delta_y = 1$, $N_x = N_y = 20$, $\Sigma = 0.7$ and $\sigma = 2$. Les mesures sont générées à $RSB = 6.71dB$ avec la valeur d'intensité correspondante I_0 de telle sorte que la première cible apparaît dans l'image 7 et disparaît dans l'image 15 ; la deuxième cible est apparaît dans l'image 15 et disparaît dans l'image 23 puis la cible 1 apparaît une autre fois de l'image 23 à l'image 30. Les vecteurs d'état cinématiques initiaux étaient $[14.2 \ 0.35 \ 7.2 \ 0.35 \ I_0]$ et $[6.2 \ 0.5 \ 4.0 \ 0.5 \ I_0]$ pour cible1, cible 2 respectivement.

Les paramètres utilisés dans la génération de la nouvelle particule cible sont $x_0 \sim U(0, N_x \Delta_x)$, $y_0 \sim U(0, N_y \Delta_y)$, $v \sim U(-1, 1)$ et $I \sim U(I_{0,\ell} - 5, I_{0,\ell} + 5)$. Les probabilités de transition dans $P_b = P_d = 0.05$. Le nombre de pixels de voisinage utilisé pour le calcul de la fonction de vraisemblance est $p = 3$. Le nombre de particules pour toutes les couches dans cette simulation est fixé à $N_p = 10000$.

La figure (5-2) présente six images de la séquence de mesures (5, 10, 15, 24, 28, 30) synthétisé selon le procédé expérimental décrit précédemment. Cette séquence d'image sert à illustrer que par examen visuel, il est impossible de détecter l'entrée et la sortie des cibles ainsi que l'emplacement de chaque cible.



Figure 5-2 Six images de la séquence des mesures avec différents modes à $RSB=6.71$ dB

La figure (5-3) montre la probabilité d'existence correspondante pour les deux cibles, ce qui indique la latence nécessaire à la détection des transitions du mode cible. En général, pour les deux cibles.

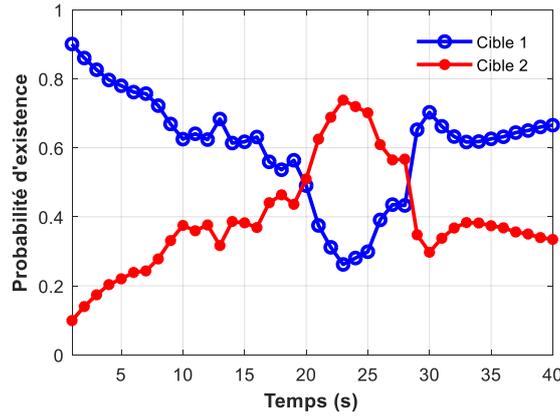


Figure 5-3 Probabilité d'existence de deux cibles à un RSB=6.71 dB

La figure (5-5) illustre la trajectoire réelle et la trajectoire estimée de chaque cible à un faible RSB=6.71dB. Notez que l'algorithme MM-MT-TBD a pu suivre les deux cibles à un faible RSB car les deux trajectoires estimées dévient légèrement des deux trajectoires réelles.

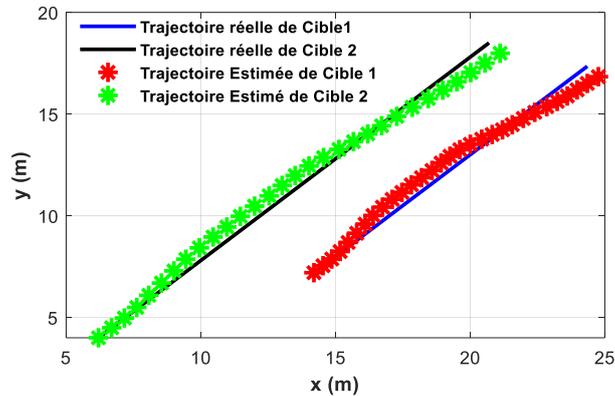


Figure 5-4 Les trajectoires estimées vers les trajectoires réelle à RSB=6.71 dB

5.4 Simulation et commentaires de l'algorithme MM-MT-TBDF-PF (les mesures radar)

Nous avons implémenté l'algorithme MM-MT-TBD-PF [130] pour suivre deux cibles radar à faible RSB. Nous supposons que le mouvement de la cible suit un modèle à virage (CT) [9]. La matrice de transition et la covariance du bruit de processus de modèle de (CT) sont données par (4.41), (4.42).

Un cadre de mesure se compose de $(48 \times 48 \times 1)$ cellules avec des résolutions de cellules $\Delta_r = 0.0766\text{m}$, $\Delta_{\dot{r}} = 0.509\text{m/s}$, et $\Delta_\theta = 0.0334\text{ rad}$. Les plages de mesure correspondantes sont : portée $[0\ 24]\text{m}$, vitesse $[-1.8\ 1.8]\text{ m/s}$ et angle azimutal $[-\pi/2\ 0]\text{rad}$ pour le capteur. Les facteurs de propagation utilisés dans les modèles de mesure sont les suivants : $\sigma_r = 1.1\text{m}$, $\sigma_{\dot{r}} = 0.35\text{m/s}$, $\sigma_\theta = 0.06\text{rad}$. La variance du bruit de mesure v_k est $r = 2$. Par conséquent, le SNR maximal correspondant au $\ell^{\text{ième}}$ cible est calculé comme suit : $SNR_{peak} = \frac{[\Delta_r \Delta_{\dot{r}} \Delta_\theta I_{k,\ell}]^2}{(2\pi^{3/2} \sigma_r \sigma_{\dot{r}} \sigma_\theta)^2 v_k}$.

Les mesures sont générées à partir d'un radar situé à la position (0,0) avec RSB = 6,27dB correspond à d'intensité I_0 telle que la première cible apparaît à l'instant $k = 6$ et disparaît dans

à $k = 19$; la deuxième cible apparaît à l'instant $k = 13$ et disparaît à $k = 26$. Le tableau (5-1) montre les combinaisons cibles.

Frame (k)	1-5	6-12	13-19	20-26	27-30
C_ℓ^i	None	T1	T1+T2	T2	None
Mode ($m_k = i$)	1	2	4	3	1

Tableau 5-1 Combinaison d'existence des cibles

Les positions et les vitesses initiales des cibles sont $(4.2,16.2)m$ et $(0.35,0.70m/s)$, $(16.2,2.2)m$ et $(-0.70,0.15)m/s$, respectivement.

Les paramètres utilisées dans la génération de la nouvelle particule cible sont $v \sim U(-1,1)$ et $SNR \sim [-3 \ 13]dB$. Les probabilités de transition dans $P_b = P_d = 0.05$. Le nombre de particules dans cette simulation est fixé à 10000 toutes les couches de filtres à particules.

La figure (5-5) montre les mesures de différent modes pour un $RSB=6.71$. Cette séquence de mesures sert à illustrer que par examen visuel, il est impossible de détecter l'entrer et la sortie des cibles ainsi que l'emplacement de chaque cible.

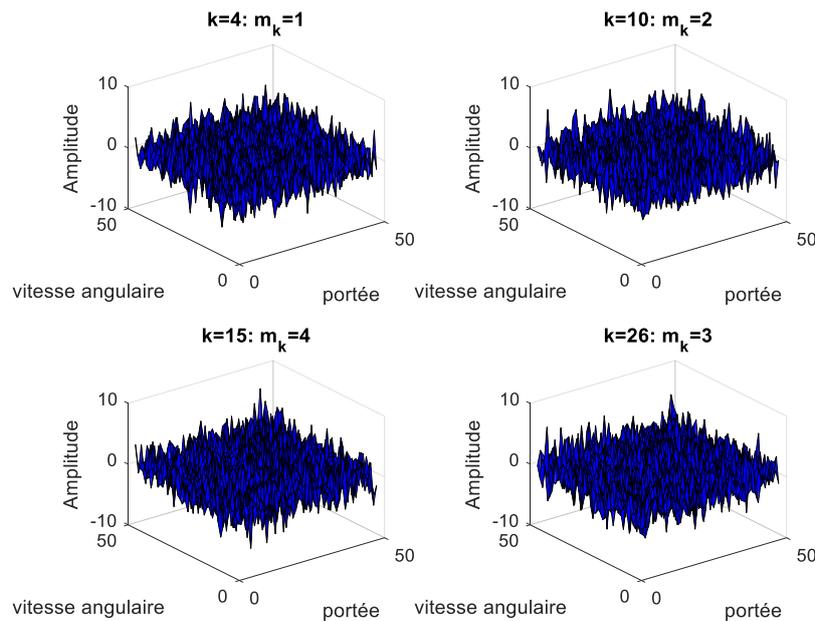


Figure 5-5 Quatre mesures avec différent modes à $RSB=6.71$

La figure 4.5 montre la probabilité moyenne estimée de différents modes. la figure illustre que l'algorithme a pu suivre les transitions des modes d'existence réelle des cibles.

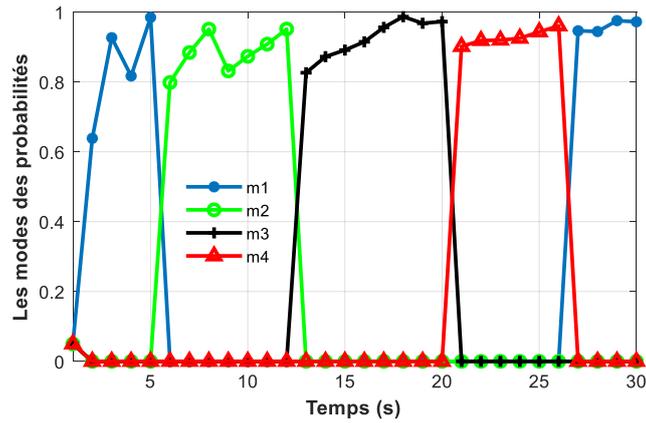


Figure 5-6 Mode de Probabilité pour l'existence des deux cibles à 6.71 dB

La figure (5-7) illustre la trajectoire réelle et la trajectoire estimée de chaque cible à un faible RSB=6.71dB. Notez que l'algorithme MM-MT-TBD a pu suivre les deux cibles à un faible RSB car les deux trajectoires estimées dévient légèrement des deux trajectoires réelles.

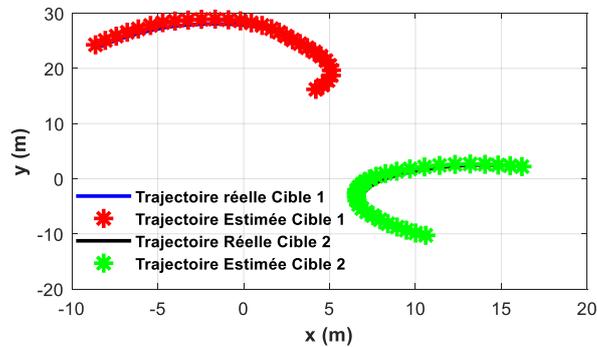


Figure 5-7 Les trajectoires estimées vers les trajectoires réelle à RSB =6.71 dB

5.5 Conclusion

Dans ce dernier chapitre, nous avons tiré un algorithme TBD pour suivre un nombre variable de cibles dans des conditions de faible RSB pouvant être implémentées avec un filtre particulière. L'algorithme MM-MT-TBD-PF estime les états cibles sous toutes les combinaisons ou modes possibles d'existence des cibles. Cet algorithme peut suivre les cibles entrant ou sortant d'une région de surveillance. Les performances de cet algorithme sont démontrées en utilisant deux cibles mobiles simulées selon deux modèles de mouvement (CV, CT) pour deux types de mesures (les mesures image, les mesures radar).

CONCLUSION ET PERSPECTIVES

L'objectif de cette thèse est d'appliquer les méthodes de filtrage des particules pour détecter et suivre une ou plusieurs cibles mobiles avec différents modèles de trajectoires dans un contexte de Track-Before-Detect (TBD).

Dans la première partie de ce travail, nous avons détaillé le filtre particulaire track-before-detect (PF-TBD) mono-cible utilisé généralement pour détecter et suivre les cibles à faible rapport signal sur bruit (RSB). Notre travail s'est concentré sur la proposition d'utiliser les différents modèles dynamiques de mouvement de cibles qui se divisent en deux catégories, des cibles non manouvrantes possédant une évolution décrite par le modèle CV à titre d'exemple, et des cibles manouvrantes caractérisées par des modèles du type CT et CA. Les simulations ont été effectuées en variant les paramètres de manœuvre ainsi que la valeur de RSB, l'objectif étant d'évaluer l'efficacité du filtre PF-TBD en termes de détection et de pistage à partir de mesures infrarouges et radar simulées. L'avantage majeur de l'approche track-before-detect est basé sur la variable d'existence de la cible et, par conséquent, le filtre particulaire développé peut détecter et suivre une cible à faible RSB. Les résultats des simulations montrent que l'algorithme PF-TBD assure de bonnes performances de détection et de pistage, pour les modèles CA et CT de cibles à faible et à forte manœuvre dans des conditions difficiles, à savoir un milieu fortement bruité ou des cibles à faible RSB.

Dans la deuxième partie de cette thèse, nous avons dérivé un algorithme de track-before-detect pour suivre un nombre variable dans des conditions de faible RSB en utilisant le filtrage particulaire. L'algorithme MM-MT-TBD-PF estime les états des cibles sous toutes les combinaisons ou modes d'existence possibles à l'aide de la fonction de densité de probabilité a posteriori mixte multi-cible. Cet algorithme est capable de détecter et de suivre des cibles entrant ou sortant d'une région de surveillance. Nous avons proposé d'appliquer l'algorithme sur le modèle de mouvement à virage CT sur des mesures radar simulées et l'algorithme assure la détection et la poursuite des cibles avec un signal sur bruit de 6 dB.

Plusieurs perspectives intéressantes peuvent être envisagées en aval du présent travail. En effet, bien que nous nous sommes cantonnés aux modèles dynamiques CV, CT et CA, d'autres modèles d'évolution cinématique plus complexes peuvent être commodément intégrés dans l'algorithme TBD-FP [9] [85]. Une approche plus complexe consisterait à implémenter les algorithmes à modèles multiples (IMM) prenant en compte la composition simultanée de plusieurs modèles dynamiques.

Par ailleurs, dans les simulations effectuées dans ce travail, la cible est supposée ponctuelle et les images radar ont été simulées en se basant sur une fonction d'étalement de point gaussienne. Une amélioration de ce modèle de mesure consisterait à considérer la fonction d'ambiguïté radar dans la formulation du modèle, ainsi que l'hypothèse de cible étendue. De

plus, le bruit de mesure modélisant la réponse radar du fouillis est supposé gaussien. Pour des applications réelles, cette hypothèse n'est pas toujours vérifiée. Il serait donc intéressant de prendre en compte des modèles statistiques plus réaliste selon le contexte étudié (distributions log-normal, Weibull etc pour le fouillis de mer).

Une autre perspective concerne la complexité calculatoire de l'algorithme TBD-FP. Nous citons à titre d'exemple les travaux de [131] qui proposent un filtre particulière efficace basé sur le choix pertinent d'une densité instrumentale en se basant sur des considérations de détection radar et permettant un gain permettant un gain de rapidité de convergence du filtre pour la détection et le pistage.

De plus, le cas multi-cible on a utilisé une méthode avec un nombre de cible connu à priori, le travail peut étendre au cas plus compliqué où le nombre de cible dans le champ de surveillance n'est pas connu.

Enfin, dans cette thèse on a utilisé des données simulées. La validation et l'évaluation des limitations de l'algorithme sur des données radar réelles est une perspective importante de nos travaux.

ANNEXE 1

Aspect de calcul :

L'erreur d'une estimation de Monte Carlo est d'ordre $O(N^{-1/2})$ est indépendante de la dimension de vecteur d'état. Cette propriété de l'erreur d'estimation repose sur l'hypothèse que N est le nombre d'échantillons statistiquement indépendants et que la fonction à intégrer est connue exactement. Dans le cas de l'estimation séquentielle de Monte Carlo, malheureusement, aucune de ces deux hypothèses n'est valable. Crisan et Doucet [132] ont récemment montré qu'une limite supérieure sur la variance de l'erreur d'estimation a la forme $c \cdot O(N^{-1})$, où c est une constante.

$$[\{r_k^n\}_{n=1}^N] = RT[\{r_{k-1}^n\}_{n=1}^N, \Pi]$$

Pour $i = 1:s$

$$c_i(0) = 0$$

POUR $j = 1:s$

$$c_i(j) = c_i(j-1) + \pi_{ij}$$

Fin pour

Pour $i = 1:N$

Générer $u_n \sim \mathcal{U}[0,1]$

$$\text{Set } i = r_{k-1}^n$$

$$m = 1$$

While $(c_i(m) < u_n)$

$$m = m + 1$$

End while

$$\text{Set } r_k^n = m$$

Fin pour

Table A-1 Régime de transitoire

Une constante. [133], cependant, soutient que la constante dans cette limite supérieure dépend fortement de la dimension du vecteur d'état. Il en déduit ensuite une formule qui indique que la variance de l'erreur pour l'intégration de Monte Carlo séquentielle dimensionnelle n_x , en utilisant un échantillonnage par importance avec une bonne densité d'importance, est approximativement linéaire dans n_x .

Pour une densité mal choisie, cependant, la variance de l'erreur devient exponentielle en n_x , correspondant à ce que l'on appelle communément la " malédiction de la dimensionnalité ".

En effet, de nombreux auteurs soulignent que le nombre de particules N requises doit être assez élevé pour les systèmes de dimensions supérieures et soulignent combien il est crucial de choisir une bonne densité d'importance.

$$[\{x_k^n, \omega_k^n\}_{n=1}^N] = RC - SIS[\{x_{k-1}^n, r_k^n, \omega_{k-1}^n\}_{n=1}^N, z_k]$$

Pour $i = 1: N$

Générer $x_k^n \sim q(x_k | x_{k-1}^n, r_k^n, z_k)$

Évaluer les poids d'importance jusqu'à une constante de normalisation

$$\tilde{\omega}_k^n = \tilde{\omega}_{k-1}^n \frac{p(z_k | x_k^n, r_k^n) p(x_k^n | x_{k-1}^n, r_k^n)}{x_k^n \sim q(x_k^n | x_{k-1}^n, r_k^n, z_k)}$$

Fin pour

Calculer la somme total des poids : $t = \text{SOMME}[\{\tilde{\omega}_k^n\}_{n=1}^N]$

Pour $n = 1: N$

* Normaliser $\omega_k^n = t^{-1} \tilde{\omega}_k^n$

Fin pour

Table A-2 Régime conditionné SIS

Pour certaines classes de modèles d'espace d'états, on peut réduire davantage le nombre de particules dans le filtre à particules en utilisant une méthode de réduction de la variance connue sous le nom de Rao-Blackwellization. L'idée est de partitionner le vecteur d'état de telle sorte qu'un composant de la partition soit le vecteur d'état de telle sorte qu'un composant de la partition soit un modèle d'espace d'état gaussien linéaire conditionnellement ; pour ce composant, on peut élaborer la solution analytiquement et utiliser un filtre de Kalman. Le filtre à particules n'est utilisé que pour la partie non linéaire non gaussienne de l'espace d'état. De cette façon, la majeure partie de l'effort de calcul est consacrée à la partie difficile du problème plutôt qu'à la partie facile. Pour expliquer la raison d'être de cette approche, examinons d'abord la définition de la variance conditionnelle de la variable aléatoire τ donnée u :

PRODUCTION SCIENTIFIQUE

Cette section présente la liste des publications, communications dans des conférences, qui ont été réalisées dans le cadre du travail de thèse.

- Article revues (3)

[1] **N. Amrouche**, A. Khenchaf, D. Berkani, "Tracking and detecting high maneuvering weak Targets," *Journal of Applied Remote Sensing (SPIE)*, 12(04):1, 035001 (04 Jul, 2018). doi: 10.1117/1.JRS.12.035001.IF=1.107

[2] **N. Amrouche**, A. Khenchaf, D. Berkani, "Tracking and Detecting moving weak Targets," *Advances in Science, Technology and Engineering Systems Journal*, vol.3, no 1, pp.467-471, February 2018. doi:10.25046/aj030157.

En Révision

[3] **N. Amrouche**, A. Khenchaf, D. Berkani, "Track-Before-Detect approach for tracking and detecting dim target with different motion models," *Journal of Aerospace Information Systems (JAIS)*, ISSN: 2327-3097. IF= 1.095

- Communication dans les conférences internationales et nationales (7)

[1] **N. Amrouche**, A. Khenchaf and D. Berkani, "Detection and tracking low maneuvering target in high noise environments," in *International Conference on Radar 2018*, Brisbane, Australia, August 2018.

[2] **N. Amrouche**, A. Khenchaf and D. Berkani, "Multiple Mode Multi-Target Tracking in high noise environment using Radar measurements," in *Sensor Signal Processing for Defence Conference*, London, United Kingdom, December 2017.

[3] **N. Amrouche**, A. Khenchaf and D. Berkani, "Multiple Target Tracking using Track Before Detect Algorithm," in *ICEAA - IEEE APWC Conference*, Verona, Italy, September 2017.

[4] **N. Amrouche**, A. Khenchaf and D. Berkani, "Détection et Poursuite des Cibles à faible Rapport Signal sur Bruit," in *10ème Conférence sur le Génie Electrique*, Alger, Algérie, April 2017.

[5] **N. Amrouche**, A. Khenchaf and D. Berkani, "Detection and Tracking Targets under Low SNR," in *IEEE International Conference on Industrial Technology*, Toronto, Canada, March 2017.

[6] **N. Amrouche**, A. Khenchaf and D. Berkani, "A Particle Filter for Multi-Target Tracking in Track Before Detect context," in *SPIE Remote Sensing Conference*, Edinburgh, Scotland, United Kingdom, September 2016.

[7] **N. Amrouche**, A. Khenchaf and D. Berkani, "Detection and Tracking Targets under Low SNR," in *5th Interplanetary iCubeSat Workshop*, Oxford, United Kingdom, May 2016.

BIBLIOGRAPHIE

BIBLIOGRAPHIE

- [1] R. E. Kalman, "No Title," *Trans. ASME, J. Basic Eng.*, vol. 1, pp. 35–45, 1960.
- [2] V. Chandrasekar and B. Zafar, "Precipitation type determination from spaceborne radar observations," *IEEE Trans. Geosci. Remote Sens.*, vol. 42, no. 10, pp. 2248–2253, 2004.
- [3] L. Mu, T. Xiangqian, and S. Ming, "Research on key technologies for collision avoidance automotive radar," *2009 IEEE Intell. Veh. Symp.*, pp. 233–236, 2009.
- [4] D. E. Sturim, M. S. Brandstein, and H. F. Silverman, "Tracking multiple talkers using microphone array measurements," *Proc. {IEEE} Int. Conf. Acoust. Speech, Signal Process.*, pp. 7–10, 1997.
- [5] C. Wang and M. S. Brandstein, "Multi-source face tracking with audio and visual data," *1999 IEEE Third Work. Multimed. Signal Process.*, pp. 169–174, 1999.
- [6] H. G. G. Okuno, K. Nakadai, K. I. I. Hidai, H. Mizoguchi, and H. Kitano, "Human-robot interaction through real-time auditory and visual multiple-talker tracking," *Intell. Robot. Syst. 2001. Proceedings. 2001 IEEE/RSJ Int. Conf.*, vol. 3, pp. 1402–1409 vol.3, 2001.
- [7] S. Churchill, C. Randell, D. Power, S. John, and E. Gill, "Data Fusion : Remote Sensing For Target Detection and Tracking," vol. 00, no. C, pp. 609–612, 2004.
- [8] A. P. Goobic, M. E. Welser, S. T. Acton, and K. Ley, "Biomedical application of target tracking in clutter," VIRGINIA UNIV CHARLOTTESVILLE DEPT OF ELECTRICAL ENGINEERING, 2001.
- [9] Y. Bar-Shalom, X.-R. Li, and T. Kirubarajan, *Estimation with Applications to Tracking and Navigation*, vol. 9. 2001.
- [10] H. W. Sorenson, *Kalman filtering: theory and application*. IEEE, 1985.
- [11] J. Sklansky, "Optimizing the dynamic parameter of a track-while-scan system," *RCA Rev.*, vol. 18, no. 2, pp. 163–185, 1957.
- [12] P. R. Kalata, " α - β Target Tracking Systems: A survey," *Am. Control Conf. 1992*, pp. 832–836, 1992.
- [13] M. Athans, R. P. Wishner, and A. Bertolini, "Suboptimal State Estimation for Continuous-Time Nonlinear Systems from Discrete Noisy Measurements," *IEEE Trans. Automat. Contr.*, vol. 13, no. 5, pp. 504–514, 1968.
- [14] M. S. Arulampalam, S. Maskell, N. Gordon, and T. Clapp, "A tutorial on particle filters for online nonlinear/nongaussian bayesian tracking," *Bayesian Bounds Param. Estim. Nonlinear Filtering/Tracking*, vol. 50, no. 2, pp. 723–737, 2007.
- [15] N. Gordon, B. Ristic, and S. Arulampalam, "Beyond the kalman filter: Particle filters for tracking

- applications,” *Artech House, London*. 2004.
- [16] S. Blackman and R. Popoli, “Design and Analysis of Modern Tracking Systems (Artech House Radar Library),” *Artech house*, 1999.
- [17] Y. Bar-Shalom and X.-R. Li, *Multitarget-multisensor tracking: principles and techniques*, vol. 19. YBs London, UK:, 1995.
- [18] S. Y. Bar and T. E. Fortmann, “Tracking and data association.” Academic Press Cambridge, 1988.
- [19] A. Farina and S. Pardini, “Track-While-Scan Algorithm In A Clutter Environment,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. AES-14, no. 5, pp. 769–779, 1978.
- [20] P. Smith and G. Buechler, “A Branching Algorithm for Discriminating and Tracking Multiple Objects,” *IEEE Trans. Automat. Contr.*, vol. 20, no. 1, pp. 101–104, 1975.
- [21] Y. Bar-Shalom and E. Tse, “Tracking in a cluttered environment with probabilistic data association,” *Automatica*, vol. 11, pp. 451–460, 1975.
- [22] T. Kirubarajan and Y. Bar-Shalom, “Probabilistic data association techniques for target tracking in clutter,” *Proc. IEEE*, vol. 92, no. 3, pp. 536–556, 2004.
- [23] Y. Bar-Shalom, F. Daum, and J. Huang, “The probabilistic data association filter,” *IEEE Control Syst. Mag.*, vol. 29, no. 6, pp. 82–100, 2009.
- [24] N. Gordon, “A hybrid bootstrap filter for target tracking in clutter,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 33, no. 1, pp. 353–358, 1997.
- [25] G. W. Pulford, “Taxonomy of multiple target tracking methods,” *IEE Proceedings-Radar, Sonar Navig.*, vol. 152, no. 5, pp. 291–304, 2005.
- [26] D. Reid, “An algorithm for tracking multiple targets,” *IEEE Trans. Automat. Contr.*, vol. 24, no. 6, pp. 843–854, 1979.
- [27] S. S. Blackman, “Multiple hypothesis tracking for multiple target tracking,” *IEEE Aerosp. Electron. Syst. Mag.*, vol. 19, no. 1, pp. 5–18, 2004.
- [28] T. Fortmann, Y. Bar-Shalom, and M. Scheffe, “Sonar tracking of multiple targets using joint probabilistic data association,” *IEEE J. Ocean. Eng.*, vol. 8, no. 3, pp. 173–184, 1983.
- [29] R. Mahler, “Random Set Theory for Target Tracking and Identification,” *Data Fusion Hand B.*, p. 14/1-14/33, 2001.
- [30] B. N. Vo, S. Singh, and A. Doucet, “Sequential Monte Carlo methods for multi-target filtering with random finite sets,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 41, no. 4, pp. 1224–1245, 2005.
- [31] R. Mahler, “Objective functions for bayesian control-theoretic sensor management, 1: Multitarget first-moment approximation,” *IEEE Aerosp. Conf. Proc.*, vol. 4, pp. 1905–1923, 2003.
- [32] R. P. S. Mahler, “Multitarget Bayes Filtering via First-Order Multitarget Moments,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 39, no. 4, pp. 1152–1178, 2003.
- [33] R. P. S. Mahler, *Statistical multisource-multitarget information fusion*. Artech House, Inc., 2007.

-
- [34] B. T. Vo, B. N. Vo, and A. Cantoni, "The cardinality balanced multi-target multi-Bernoulli filter and its implementations," *IEEE Trans. Signal Process.*, vol. 57, no. 2, pp. 409–423, 2009.
- [35] H. Sidenbladh, "Multi-target particle filtering for the probability hypothesis density," *arXiv Prepr. cs/0303018*, 2003.
- [36] R. D. Palmer, "FUNDAMENTALS OF RADAR SIGNAL PROCESSING," *Bull. Am. Meteorol. Soc.*, vol. 89, no. 7, p. 1037, 2008.
- [37] S. M. Kay, "Fundamentals of Statistical Signal Processing, volume 1 of," *Signal Processing*, 1993.
- [38] M. Skolnik, "Introduction to Radar systems," *IEEE Aerosp. Electron. Syst. Mag.*, vol. 16, no. 10, p. 19, 2001.
- [39] G. A. Richards, "Application of the Hough transform as a track-before-detect method," 1996.
- [40] W. Yi, L. Kong, J. Yang, and X. Deng, "A tracking approach based on dynamic programming track-before-detect," *Radar Conf. 2009 IEEE*, pp. 0–3, 2009.
- [41] S. M. Tonbsen and Y. Bar-Shalom, "Maximum likelihood track-before-detect with fluctuating target amplitude," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 34, no. 3, pp. 796–809, 1998.
- [42] D. J. Salmond and H. Birch, "A particle filter for track-before-detect," *Proc. 2001 Am. Control Conf. (Cat. No.01CH37148)*, pp. 3755–3760 vol.5, 2001.
- [43] S. J. Davey, B. Cheung, and M. G. Rutten, "Track-Before-Detect for sensors with complex measurements," *Inf. Fusion (FUSION)*, 2009, pp. 618–625, 2009.
- [44] Y. Boers and J. N. Driessen, "Multitarget particle filter track before detect application," *IEE Proceedings-Radar, Sonar Navig.*, vol. 151, no. 6, pp. 351–357, 2004.
- [45] M. Taj and A. Cavallaro, "Multi-camera track-before-detect," *2009 3rd ACM/IEEE Int. Conf. Distrib. Smart Cameras, ICDSC 2009*, 2009.
- [46] F. Lehmann, "Recursive bayesian filtering for multitarget track-before-detect in passive radars," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 48, no. 3, pp. 2458–2480, 2012.
- [47] K. Punithakumar, T. Kirubarajan, and A. Sinha, "A sequential Monte Carlo probability hypothesis density algorithm for multitarget track-before-detect," in *Signal and Data Processing of Small Targets 2005*, 2005, vol. 5913, p. 59131S.
- [48] J. Wong and B. Vo, "Multi-Bernoulli based track-before-detect with road constraints," *2012 15th Int. Conf. Inf. Fusion*, pp. 840–846, 2012.
- [49] S. P. Ebenezer and A. Papandreou-Suppappola, "Generalized Recursive Track-Before-Detect with Proposal Partitioning for Tracking Varying Number of Multiple Targets in Low SNR," *IEEE Trans. Signal Process.*, vol. 64, no. 11, pp. 2819–2834, 2016.
- [50] S. M. Kay, *Fundamentals of statistical signal processing: Practical algorithm development*, vol. 3. Pearson Education, 2013.
- [51] G. Turin, "An introduction to matched filters," *IRE Trans. Inf. theory*, vol. 6, no. 3, pp. 311–329, 1960.
- [52] S. Kingsley and S. Quegan, *Understanding radar systems*, vol. 2. SciTech Publishing, 1999.
-

-
- [53] M. Curie, “Doctorat conjoint Télécom & Management SudParis et Université Pierre et Pistage de cibles manoeuvrantes en radar passif par ltrage à particules gaussiennes,” 2011.
- [54] P. Swerling, “Probability of detection for fluctuating targets,” *IRE Trans. Inf. Theory*, vol. 6, no. 2, pp. 269–308, 1960.
- [55] R. Nitzberg, *Radar signal processing and adaptive systems*. Artech house Boston, 1999.
- [56] E. R. Billam, “Phased array radar and the detection of ‘low observables,’” *IEEE Int. Conf. Radar*, vol. 0, pp. 491–495.
- [57] W. K. Pratt, *Digital Image Processing: College Edition*. Wiley, 2017.
- [58] D. S. K. Chan, “Spatial processing techniques for the detection of small targets in IR clutter,” in *Signal and Data Processing of Small Targets 1990*, 1990, vol. 1305, p. 53.
- [59] P. F. Singer and D. M. Sasaki, “<title>The heavy-tailed distribution of a common CFAR detector</title>,” no. May 1996, pp. 124–140, 1995.
- [60] P. Density, “NRL Report 8895 Power Density and Threshold Control Strategies for Radar,” no. 202.
- [61] S. D. Blostein and T. S. Huang, “Detecting Small, Moving Objects in Image Sequences Using Sequential Hypothesis Testing,” *IEEE Trans. Signal Process.*, vol. 39, no. 7, pp. 1611–1629, 1991.
- [62] S. D. Blostein and H. S. Richardson, “A sequential detection approach to target tracking,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 30, no. 1, pp. 197–212, 1994.
- [63] A. D. Stocker and P. D. Jensen, “<title>Algorithms and architectures for implementing large-velocity filter banks</title>,” no. August 1991, pp. 140–155, 1991.
- [64] N. Wiener and I. Extrapolation, “Smoothing of stationary time series.” Wiley, New York, 1949.
- [65] S. J. Julier and J. K. Uhlmann, “New extension of the Kalman filter to nonlinear systems,” in *Signal processing, sensor fusion, and target recognition VI*, 1997, vol. 3068, pp. 182–194.
- [66] S. Julier, J. Uhlmann, and H. F. Durrant-Whyte, “A new method for the nonlinear transformation of means and covariances in filters and estimators,” *IEEE Trans. Automat. Contr.*, vol. 45, no. 3, pp. 477–482, 2000.
- [67] J. M. Hammersley and K. W. Morton, “Poor man’s monte carlo,” *J. R. Stat. Soc. Ser. B*, pp. 23–38, 1954.
- [68] N. J. Gordon, D. J. Salmond, and A. F. M. Smith, “Novel approach to nonlinear/non-Gaussian Bayesian state estimation,” in *IEE Proceedings F (Radar and Signal Processing)*, 1993, vol. 140, no. 2, pp. 107–113.
- [69] E. Mazor, A. Averbuch, Y. Bar-Shalom, and J. Dayan, “Interacting multiple model methods in target tracking: A survey,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 34, no. 1, pp. 103–123, 1998.
- [70] S. S. Blackman, “Multiple-target tracking with radar applications,” *Dedham, MA, Artech House, Inc., 1986, 463 p.*, 1986.
- [71] R. A. Singer, R. G. Sea, and K. B. Housewright, “Derivation and Evaluation of Improved
-

-
- Tracking Filters for Use in Dense Multitarget Environments,” *IEEE Trans. Inf. Theory*, vol. 20, no. 4, pp. 423–432, 1974.
- [72] Y. Bar-Shalom, *Tracking and data association*. Academic Press Professional, Inc., 1987.
- [73] F. R. Castella, “Sliding Window Detection Probabilities,” *Aerosp. Electron. Syst. IEEE Trans.*, vol. AES-12, no. 6, pp. 815–819, 1976.
- [74] K. C. Chang and H. M. Shertukde, “Track Formation I N Clutter,” pp. 13–17, 1989.
- [75] Y. Barniv, “Dynamic programming algorithm for detecting dim moving targets,” *Multitarget-Multisensor Tracking: Advanced Applications*, vol. 4. chapter, 1990.
- [76] J. L. Hartnon, “Track_before_detect Performance For A High PRF Search Mode,” pp. 11–15, 1991.
- [77] M. C. Smith and E. M. Winter, “On the detection of target trajectories in a multi-target environment,” *Seventeenth IEEE Conf. Decis. Control*, 1978.
- [78] Y. Li *et al.*, “Multisensor Hough transform and logic-based track initiation techniques,” pp. 729–736, 1997.
- [79] B. D. Carlson, E. D. Evans, S. L. Wilson, and M. I. T. Lincoln, “Search radar detection and track with the hough transform part III: Detection performance with binary integration,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 30, no. 1, pp. 116–125, 1994.
- [80] D. P. Casasent and J. Slaski, “Optical track initiator for multitarget tracking,” *Appl. Opt.*, vol. 27, no. 21, pp. 4546–4553, 1988.
- [81] J. Arnold, S. W. Shaw, and H. Pasternack, “Efficient target tracking using dynamic programming,” *Aerosp. Electron. Syst. IEEE Trans.*, vol. 29, no. 1, pp. 44–56, 1993.
- [82] C. A. Barlow and S. S. Blackman, “<title>New Bayesian track-before-detect design and performance study</title>,” no. September 1998, pp. 181–191, 1998.
- [83] H. Tanizaki, *Nonlinear filters: estimation and applications*. Springer Science & Business Media, 2013.
- [84] D. D. Sworder and J. E. Boyd, *Estimation problems in hybrid systems*. Cambridge University Press, 1999.
- [85] X. R. Li and V. P. Jilkov, “Survey of Maneuvering Target Tracking. Part I: Dynamic Models,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 39, no. 4, pp. 1333–1364, 2003.
- [86] J. E. Handschin and D. Q. Mayne, “Monte Carlo techniques to estimate the conditional expectation in multi-stage non-linear filtering,” *Int. J. Control*, vol. 9, no. 5, pp. 547–559, 1969.
- [87] H. Akashi and H. Kumamoto, “Brief paper: Random sampling approach to state estimation in switching environments,” *Autom. (Journal IFAC)*, vol. 13, no. 4, pp. 429–434, 1977.
- [88] G. Salut, “Le thème non-linéaire en automatique et traitement du signal,” *Journées Natl. du Trait. du signal images, Chantilly*, vol. 50, p. 346, 1989.
- [89] A. Doucet, N. De Freitas, and N. Gordon, “An introduction to sequential Monte Carlo methods,” in *Sequential Monte Carlo methods in practice*, Springer, 2001, pp. 3–14.
- [90] J. Von, N. Sujnjnary, and G. E. Forsythe, “Various Techniques Used in Connection With
-

- Random Digits,” *Natl. Bur. Stand. Appl. Math Ser.*, vol. 38, no. 12, pp. 36–38, 1951.
- [91] L. Devroye, “Sample-based non-uniform random variate generation,” in *Proceedings of the 18th conference on Winter simulation*, 1986, pp. 260–265.
- [92] N. Metropolis, A. W. Rosenbluth, M. N. Rosenbluth, A. H. Teller, and E. Teller, “Equation of state calculations by fast computing machines,” *J. Chem. Phys.*, vol. 21, no. 6, pp. 1087–1092, 1953.
- [93] W. K. Hastings, “Monte Carlo sampling methods using Markov chains and their applications,” 1970.
- [94] A. W. Marshall, “The use of multi-stage sampling schemes in Monte Carlo computations,” RAND CORP SANTA MONICA CALIF, 1954.
- [95] A. Doucet, S. Godsill, and C. Andrieu, “methods for Bayesian filtering,” *Stat. Comput.*, pp. 197–208, 2000.
- [96] J. MacCormick and A. Blake, “A probabilistic exclusion principle for tracking multiple objects,” *Proc. Seventh IEEE Int. Conf. Comput. Vis.*, vol. 39, no. 1, pp. 572–578 vol.1, 1999.
- [97] A. Kong, J. S. Liu, and W. H. Wong, “Sequential imputations and Bayesian missing data problems,” *J. Am. Stat. Assoc.*, vol. 89, no. 425, pp. 278–288, 1994.
- [98] J. S. Liu and R. Chen, “Sequential Monte Carlo methods for dynamic systems,” *J. Am. Stat. Assoc.*, vol. 93, no. 443, pp. 1032–1044, 1998.
- [99] R. Nedvěď, T. Košan, V. Šmídl, and Z. Peroutka, “FPGA Implementation of Rao-Blackwellized Particle Filter and its Application to Sensorless Drive Control,” *IFAC Proc. Vol.*, vol. 47, no. 3, pp. 8669–8674, 2014.
- [100] A. Doucet, “On Sequential Simulation-Based Methods for Bayesian Filtering,” *Signal Processing*, no. CUED/F-INFENG/TR.310, pp. 1–26, 1998.
- [101] G. Salut, “Procédé et système pour l’estimation non-linéaire optimale des processus dynamiques en temps réel,” *Brev. INPI*, vol. 94, no. 07274, pp. 95595255–95595256.
- [102] M. K. Pitt and N. Shephard, “Filtering via simulation: Auxiliary particle filters,” *J. Am. Stat. Assoc.*, vol. 94, no. 446, pp. 590–599, 1999.
- [103] P. Fearnhead, “Sequential Monte Carlo methods in filter theory.” University of Oxford Oxford, 1998.
- [104] C. Musso, N. Oudjane, and F. Le Gland, “Improving regularised particle filters,” in *Sequential Monte Carlo methods in practice*, Springer, 2001, pp. 247–271.
- [105] C. Musso and N. Oudjane, “Regularisation schemes for branching particle systems as a numerical solving method of the nonlinear filtering problem,” in *Irish Signals and Systems Conference, Dublin, Ireland, June 25, 26, 1998, ONERA, TP*, 1998, no. 1998–102.
- [106] S. McGinnity and G. W. Irwin, “Multiple model bootstrap filter for maneuvering target tracking,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 36, no. 3 PART 1, pp. 1006–1012, 2000.
- [107] D. S. Angelova, “Application of monte carlo method for tracking maneuvering target in clutter,” *Math. Comput. Simul.*, vol. 1851, pp. 1–9, 2000.

-
- [108] Y. Boers and H. Driessen, "Hybrid state estimation: A target tracking application," *Automatica*, vol. 38, no. 12, pp. 2153–2158, 2002.
- [109] C. Hue, J. P. Le Cadre, and P. Perez, "Sequential Monte Carlo methods for multiple target tracking and data fusion," *IEEE Trans. Signal Process.*, vol. 50, no. 2, pp. 309–325, 2002.
- [110] M. Rollason, "A particle filter for track-before-detect of a target with unknown amplitude," *IEE Int. Semin. Target Track. Algorithms Appl.*, vol. 2001, pp. 14–14, 2001.
- [111] F. E. Daum and R. J. Fitzgerald, "Importance of resolution in multiple-target tracking," in *Signal and Data Processing of Small Targets 1994*, 1994, vol. 2235, pp. 329–339.
- [112] S. B. Colegrove, A. W. Davis, and J. K. Ayliffe, "Track initiation and nearest neighbours incorporated into probabilistic data association," *J. Electr. Electron. Eng. Aust.*, vol. 6, no. 3, pp. 191–198, 1986.
- [113] D. Musicki, R. Evans, and S. Stankovic, "Integrated probabilistic data association," *Trans. Autom. Control*, vol. 39, no. 6, pp. 1237–1241, 1994.
- [114] M. A. Richards, *Fundamentals of radar signal processing*. Tata McGraw-Hill Education, 2005.
- [115] M. G. Rutten, B. Ristic, and N. J. Gordon, "A comparison of particle filters for recursive track-before-detect," *2005 7th Int. Conf. Inf. Fusion, FUSION*, vol. 1, pp. 169–175, 2005.
- [116] N. Amrouche, A. Khenchaf, and D. Berkani, "Tracking and detecting high maneuvering weak targets," *J. Appl. Remote Sens.*, vol. 12, no. 04, p. 1, 2018.
- [117] D. J. Ballantyne, H. Y. Chan, and M. A. Kouritzin, "Novel branching particle method for tracking," in *Signal and Data Processing of Small Targets 2000*, 2000, vol. 4048, pp. 277–288.
- [118] H. V. Poor, *An introduction to signal detection and estimation*. Springer Science & Business Media, 2013.
- [119] A. Khenchaf, N. Amrouche, and D. Berkani, "Detection and Tracking of Moving Target using Track Before Detect (TBD) method," in *iCube Sat*, 2016.
- [120] N. Amrouche and A. Khenchaf, "Detection and Tracking Low Maneuvering Target in a High Noise Environments."
- [121] N. Amrouche, A. Khenchaf, and D. Berkani, "Detection and tracking targets under low SNR," *Proc. IEEE Int. Conf. Ind. Technol.*, pp. 992–996, 2017.
- [122] N. Amrouche, A. Khenchaf, and D. Berkani, "Tracking and Detecting moving weak Targets."
- [123] N. Amrouche, A. Khenchaf, and D. Berkani, "Détection et Poursuite des Cibles à faible Rapport Signal sur Bruit," in *10 ème Conférence sur le Génie Electrique CGE'10*.
- [124] N. Wang, G. H. Wang, H. B. Yu, and D. Sheng, "Particle initialization effect of particle filter based track-before-detect algorithm," *IEEE Natl. Radar Conf. - Proc.*, no. 4, pp. 180–184, 2011.
- [125] S. Reuter, B. T. Vo, B. N. Vo, and K. Dietmayer, "The labeled multi-Bernoulli filter," *IEEE Trans. Signal Process.*, vol. 62, no. 12, pp. 3246–3260, 2014.
- [126] M. Rutten, N. Gordon, and S. Maskell, "Efficient Particle-Based Track-before-detect in {Rayleigh} Noise," *Proc. 7th Intl. Conf. Multisens. Inf. Fusion*, no. 1, pp. 693–700, 2004.
- [127] S. P. Ebenezer and A. Papandreou-suppappola, "Multiple Mode Track-Before-Detect for
-

- Multiple Targets,” no. January, pp. 328–333, 2012.
- [128] S. P. Ebenezer, *Multiple Radar Target Tracking in Environments with High Noise and Clutter*. Arizona State University, 2015.
- [129] N. Amrouche, A. Khenchaf, and D. Berkani, “Multiple target tracking using track before detect algorithm,” *Proc. 2017 19th Int. Conf. Electromagn. Adv. Appl. ICEAA 2017*, pp. 692–695, 2017.
- [130] N. Amrouche, A. Khenchaf, and D. Berkani, “Multiple Mode Multi-Target Tracking in High Noise Environment Using Radar Measurements,” *2017 Sens. Signal Process. Def. Conf. SSPD 2017*, vol. 2017–Janua, 2017.
- [131] A. Lepoutre, “Detection and tracking in Track-Before-Detect context with particle filter.” Université Rennes 1, 2016.
- [132] D. Crisan and A. Doucet, “A survey of convergence results on particle filtering methods for practitioners,” *IEEE Trans. Signal Process.*, vol. 50, no. 3, pp. 736–746, 2002.
- [133] F. Daum and J. Huang, “Curse of Dimensionality and Particle Filters,” *Proc. IEEE Aerosp. Conf.*, vol. 4, pp. 1979–1993, 2003.