

UNIVERSITE DE BLIDA 1

Institut d'Aéronautique et des Etudes Spatiales

MEMOIRE DE MAGISTER

(en Aéronautique)

Spécialité : Aéronautique

**POURSUITE MULTI-CIBLES DANS UN ENVIRONNEMENT DE
CIBLES MANOEUVRANTES EN PRESENCE DE CLUTTER AVEC
DES MODELES MULTIPLES INTERAGISSANT**

Par

DJEMA Nadji

Devant le jury composé de :

M. S.BOUKRAA	Professeur, U.S.D.B	Président
M. M.BENSLAMA	Professeur, U.Constantine	Rapporteur
M.F.SOLTANI	Professeur, U.Constantine	Examineur
M.L.BOUNATIRO	Professeur, U.S.D.B	Examineur
M. M.LAGHA	Maitre de Conférences, U.S.D.B	Co-rapporteur

Blida, Juin 2014

ملخص

نقترح في هذه المذكرة التطرق لمشكلة تتبع وتصنيف الأهداف المتعددة. توجد تقنيات مختلفة لحل معضلة تتبع الأهداف، نذكر على سبيل المثال مرشح كالمان مع مختلف طبعاته. إن مظهر تعدد الأهداف يبرز في قسم ربط المعطيات، حيث أننا استخدمنا طريقة نظرية الأدلة لربط المعطيات، و قارنا حسن سير هذه الطريقة مع حسن سير الطرق "JPDA" و "NN". وقد استخدمنا لتصنيف حركة الأهداف في كل لحظة طريقة ال "IMM" المكيفة مع مرشح كالمان الممدد. الدراسة تمت على حالتين، مع وبدون وجود فوضى حدثت من انعكاس على السطح.

و قد قمنا بعدة تجارب تمثيلية لإظهار حسن سير مختلف الخوارزميات المستعملة في هذه المذكرة وفي ظروف مختلفة.

كلمات مفتاحية

متابعة اهداف متعددة، نظرية الأدلة ، JPDA ، NN، تصنيف الحركة، مرشح كالمان الممدد، طريقة IMM، فوضى السطح.

RESUME

Dans ce mémoire, nous nous intéressons à la poursuite multi-cibles et la classification de mouvements. Plusieurs techniques sont employées pour la poursuite de cibles telles que le filtrage Kalman avec ses versions. L'aspect multi-cibles est illustré dans la partie d'association de données, où la théorie de "Dempster-Shafer" est utilisée et validée en comparant ses performances avec celles des méthodes JPDA et NN. Concernant la classification de mouvement de cibles, les IMM associés au filtrage de Kalman étendue sont employés. L'étude est réalisée dans deux situation, avec et sans la présence d'un clutter de surface.

Des simulations numériques illustrées par des figures sont exposées. Elles permettent de traiter les performances des algorithmes utilisés dans différents scénarios.

Mots clés

Poursuite multi-cibles, théorie de "Dempster-Shafer", JPDA, NN, classification de mouvements, filtrage de Kalman étendue, modèles multiple interagissant (IMM), clutter de surface.

ABSTRACT

In this work, we are interested in the multi targets tracking and classification of movements. Several techniques are employed for target tracking such as Kalman filtering with its versions. The aspect multi targets is illustrated in the part of data association, where the theory of "Dempster-Shafer" is used and validated by comparing its performances with those of JPDA and NN method. For the targets movement classification at every moment, we use the IMM associated with the extended Kalman filter. The study is carried out in two situations, with and without the presence of a surface clutter.

Many simulations come to illustrate the performances of the algorithms used in various scenarios.

Key Words

Tracking of multiple targets, theory of "Dempster-Shafer", JPDA, NN, classification of movements, Extended Kalman filtering, Interacting Multiple Models (IMM), surface clutter.

REMERCIEMENTS

Rendant grâce à **DIEU** le tout puissant qui nous a permis de terminer ce travail.

En deuxième lieu mes remerciements vont en particulier à mon directeur de thèse, Monsieur BENSLAMA Malek, J'aimerais bien souligner que ce mémoire n'aurait jamais existé sans lui, je le remercie beaucoup pour son aide par ses orientations et son suivi attentif au long de ce travail. Mes remerciements vont aussi à mon co-promoteur monsieur LAGHA Mhand pour ses précieux conseils.

J'adresse mes vifs remerciements à Madame la directrice de la bibliothèque centrale de l'université de Constantine 1 pour son aide le long de ce travail aussi bien que sa gentillesse.

Je remercie Monsieur Saleh BOUKRAA, Professeur à l'institut d'Aéronautique et des Etudes Spatiales de U.S.D de Blida, d'avoir accepté de présider le Jury.

Je remercie Monsieur Loth BOUNATIRO, maître de conférences à l'institut d'aéronautique et des études spatiales de U.S.D de Blida, d'avoir accepté de faire partie du jury.

Je remercie Monsieur Faouzi SOLTANI, Professeur au département d'Electronique de Constantine, d'avoir accepté de faire partie du jury.

Je tiens ensuite à remercier tout spécialement Lieutenant SADIKI Oussama pour son aide.

Je tien également à remercier tous les membres du laboratoire des sciences aéronautique, de département aéronautique à Blida.

Evidemment, je remercie chaleureusement toute ma famille.

Merci à tous mes amis.

Ainsi, que ceux et celles que j'ai involontairement oubliés et qui ont participé de près ou de loin à l'élaboration du présent travail, qu'ils trouvent ici l'expression de ma gratitude.

TABLE DES MATIERES

RESUMES

REMERCIEMENTS

TABLE DES MATIERES

LISTE DES ILLUSTRATIONS GRAPHIQUES ET TABLEAUX

LISTE DES SYMBOLES ET DES ABREVIATIONS

INTRODUCTION

11

1. GENERALITES SUR LA POURSUITE DES CIBLES

15

1.1. Introduction

15

1.2. Le suivi de cibles

16

1.3. Types de cibles

17

1.3.1. Cibles non manoeuvrantes

17

1.3.2. Cibles manoeuvrantes

18

1.4. Adaptation à la manœuvre

19

1.4.1. Approche basée sur le changement des paramètres de poursuite

19

1.4.2. Approche basée sur le changement de la dimension du modèle

20

1.4.3. Approche basée sur l'estimation de l'accélération

20

1.4.4. Approche à Modèles Multiples

21

1.5. Description d'un système de poursuite multi-cibles

23

1.5.1. Description

23

1.5.2. Validation des mesures

24

1.6. Problèmes d'association de pistes

25

1.7. Catégories d'association de données

26

1.8. Conclusion

27

2. ASSOCIATION DE DONNÉES PAR LA THÉORIE DE
DEMPSTER-SHAFER

28

2.1. Introduction

28

2.2. Théorie de Dempster-Shafer

29

2.2.1. Cadre de discernement	29
2.2.2. Fonction de masse élémentaire	30
2.2.3. Les fonctions de crédibilité et de plausibilité	31
2.2.4. Autres mesures de la fonction de masse	34
2.3. Règles de combinaison	35
2.3.1. Règles de combinaisons de base	35
2.3.2. Règle de combinaison de Dempster	36
2.4. Règles de décision	37
2.5. Modélisation des BF	38
2.6. Simulation numérique	40
2.7. Conclusion	49
3. ETUDES DES PERFORMANCES DE LA POURSUITE DE CIBLES NON MANOEUVRANTES	50
3.1. Introduction	50
3.2. Modélisation d'état	51
3.3. Filtre de Kalman	53
3.3.1. Les applications du filtre	53
3.3.2. Filtre de Kalman discret	53
3.3.3. Filtre de Kalman étendu	55
3.4. Autres méthodes d'association de données	58
3.4.1. Méthode du plus proche voisin NN	58
3.4.2. Filtre d'association de données par probabilités conjointes (JPDA)	59
3.5. Modélisation du Clutter (fouillis) de mer	61
3.6. Simulation numérique	63
3.7. Conclusion	80
4. POURSUITE MULTI-CIBLES ET CLASSIFICATION DE MOUVEMENTS	81
4.1. Introduction	81
4.2. Détecteur de manœuvre	82
4.2.1. Techniques de détection de manœuvres	82
4.2.2. Techniques basées sur l'estimation de l'accélération	84
4.3. Modèle Multiple Interagissant (IMM)	85

4.4. Modèle multiples interagissant à base de filtre de Kalman étendu (IMM-EKF)	91
4.5. Modélisation du clutter (fouillis) de terre	94
4.6. Simulation numérique	95
4.7. Conclusion	116
CONCLUSION	117
APPENDICE	119
A. Distribution de Weibull	119
B. Mesure des performances	121
C. Distribution lognormal	123
REFERENCES	125

LISTE DES ILLUSTRATIONS GRAPHIQUES ET TABLEAUX

Figure 1.1 : Structure d'un système de surveillance	16
Figure 1.2 : Le module de pistage	16
Figure 1.3 : Cibles (a) non manoeuvrantes (b) manoeuvrantes	17
Figure 1.4 : Adaptation des dimensions de la fenêtre de corrélation	19
Figure 1.5 : Filtrage avec changement de la dimension du filtre	20
Figure 1.6 : Schéma bloc d'un système MM	21
Figure 1.7 : Schéma bloc du système à Modèles Multiples Interactifs (IMM)	22
Figure 1.8 : Schéma synoptique d'un algorithme de poursuite	23
Figure 1.9 : Exemple de situation de conflit dans un problème de poursuite	26
Figure 2.1 : Crédibilité et plausibilité d'un ensemble A	33
Figure 2.2 : Représentation d'évidence d'un ensemble A	33
Figure 2.3 : Différentes mesures de fonction de masse	34
Figure 2.4 : Association des mesures aux cibles correspondantes	40
Figure 2.5 : Etapes d'association de données	41
Figure 2.6 : Trajectoires réelles et estimées par DST des trois cibles parallèles	44
Figure 2.7 : Taux d'association des trois cibles parallèles	45
Figure 2.8 : Trajectoires réelles et estimées par DST des trois cibles qui se croisent	46
Figure 2.9 : Taux d'association des trois cibles qui se croisent	47
Figure 3.1 : Schéma de l'algorithme du filtre de Kalman	54
Figure 3.2 : Schéma de l'algorithme du filtre de Kalman étendu	57
Figure 3.3 : Exemple d'association NN	59
Figure 3.4 : Exemple d'association JPDA	60
Figure 3.5 : L'algorithme (JPDA, NN, CD)-EKF	64
Figure 3.6 : Trajectoires réelles et estimées par CD et JPDA pour $(S1, Sc1)$	66
Figure 3.7 : Trajectoires réelles et estimées par CD et NN pour $(S1, Sc1)$	67
Figure 3.8 : Les mesures de performances CD, NN et JPDA pour $(S1, Sc1)$	68
Figure 3.9 : Trajectoires réelles et estimées par CD et JPDA pour $(S1, Sc2)$	69
Figure 3.10 : Trajectoires réelles et estimées par CD et NN pour $(S1, Sc2)$	70

Figure 3.11 : Les mesures de performances CD, NN et JPDA pour (S1, Sc2)	71
Figure 3.12 : Trajectoires réelles et estimées par CD et JPDA pour (S2, Sc1)	73
Figure 3.13 : Trajectoires réelles et estimées par CD et NN pour (S2, Sc1)	74
Figure 3.14 : Les mesures de performances CD, NN et JPDA pour (S2, Sc1)	75
Figure 3.15 : Trajectoires réelles et estimées par CD et JPDA pour (S2, Sc2)	76
Figure 3.16 : Trajectoires réelles et estimées par CD et NN pour (S2, Sc2)	77
Figure 3.17 : Les mesures de performances CD, NN et JPDA pour (S2, Sc2)	78
Figure 4.1 : Processus de filtrage en présence d'un détecteur de manœuvre	82
Figure 4.2 : Schéma descriptif de l'algorithme <i>IMM</i>	90
Figure 4.3 : L'algorithme (JPDAF, NN, CD)-IMM-EKF	96
Figure 4.4 : Trajectoires réelles et estimées par CD et JPDA pour (S3, Sc3)	98
Figure 4.5 : Trajectoires réelles et estimées par CD et NN pour (S3, Sc3)	99
Figure 4.6 : Les mesures de performances CD, NN et JPDA pour (S3, Sc3)	100
Figure 4.7 : la probabilité de classification de mouvement pour (S3, Sc3)	101
Figure 4.8 : Trajectoires réelles et estimées par CD et JPDA pour (S3, Sc4)	102
Figure 4.9 : Trajectoires réelles et estimées par CD et NN pour (S3, Sc4)	103
Figure 4.10 : Les mesures de performances CD, NN et JPDA pour (S3, Sc4)	104
Figure 4.11 : la probabilité de classification de mouvement pour (S3, Sc4)	105
Figure 4.12 : Trajectoires réelles et estimées par CD et JPDA pour (S4, Sc3)	107
Figure 4.13 : Trajectoires réelles et estimées par CD et NN pour (S4, Sc3)	108
Figure 4.14 : Les mesures de performances CD, NN et JPDA pour (S4, Sc3)	109
Figure 4.15 : la probabilité de classification de mouvement pour (S4, Sc3)	110
Figure 4.16 : Trajectoires réelles et estimées par CD et JPDA pour (S4, Sc4)	111
Figure 4.17 : Trajectoires réelles et estimées par CD et NN pour (S4, Sc4)	112
Figure 4.18 : Les mesures de performances CD, NN et JPDA pour (S4, Sc4)	113
Figure 4.19 : la probabilité de classification de mouvement pour (S4, Sc4)	114
Tableau 2.1 : Génération des masses	39
Tableau 2.2 : Tableau de croyance	39
Tableau 3.1 : Tableau des hypothèses	60

LISTE DES SYMBOLES ET DES ABREVIATIONS

A, B	: Sous ensembles du cadre de discernement
BEL	: Fonction de Crédibilité
BF	: Fonction de Croyance
CD	: Combinaison de Dempster
CJPDA	: Cheap JPDA
DST	: Théorie de Dempster-Shafer
$E[.]$: Espérance mathématique
EKF	: Filtre de Kalman Etendu
F_m	: Matrice de transition d'état de $m^{\text{ème}}$ modèle de mouvement
FS	: Ensemble Floue
$f\{.\}$: La fonction de densité de probabilité d'une variable continue
G_m	: Matrice de contrôle de $m^{\text{ème}}$ modèle de mouvement
GPB-2	: Estimateur Pseudo-Bayésien Généralisé de Deuxième Ordre
H_N	: hypothèses simples (Singleton)
h	: Matrice de mesure
IMM	: Modèles Multiples Interagissant
JPDA	: Association de Données par Probabilités Conjointes
KF	: Filtre de Kalman
K	: Degré de conflit
M	: nombre de modèles de mouvement
MHT	: Filtre de Poursuite à Hypothèses Multiple
$m(.)$: Fonction de masse élémentaire d'un ensemble
N	: Nombre d'échantillons
NN	: Plus Proche Voisin
N_{CIB}	: nombre de cibles
N_{OBS}	: nombre de mesures
N^{MC}	: nombre de jeu de Monte-Carlo
$P\{.\}$: La probabilité d'un événement discret
PDF	: Fonction de Densité de Probabilité

P_{ij}	: Probabilités des transitions
P_k	: Matrice de covariance de l'estimation
$P_{k/k-1}$: Matrice de covariance de l'estimation prédite
PL	: Fonction de Plausibilité
Q(.)	: Fonction de communalité (interchangeabilité)
Q_K	: Matrice de covariance du bruit du processus
q	: bruit de modèle
R	: matrice de covariance de bruit de mesure
REQMP	: Erreur Quadratique Moyenne en Position
REQMV	: Erreur Quadratique Moyenne en Vitesse
T	: Période d'échantillonnage
U_{K-1}	: paramètres de commande
V_k	: bruit de mesure
W_k	: bruit d'état
\underline{X}_k	: Vecteur d'état de la cible à l'instant k
$\hat{\underline{X}}_k$: Vecteur d'estimation d'état de la cible à l'instant k
$\hat{\underline{X}}_{k/k-1}$: Vecteur d'estimation à priori à l'instant k
\mathcal{X}_k^0	: Vecteur approcher d'état à l'instant k
x_c, y_c	: position du capteur
\underline{Z}_k	: Vecteur de mesure à l'instant k
\mathcal{Z}_k^0	: Vecteur approcher de mesure à l'instant k
α	: paramètre d'échelle de la distribution de Weibull
β	: paramètre de forme de la distribution de Weibull
Θ	: Cadre de discernement
2^Θ	: Cadre de raisonnement de base
\emptyset	: L'ensemble vide
$\delta(.)$: Fonction de décision
σ_x^2	: Variance de l'erreur sur la position x
σ_y^2	: Variance de l'erreur sur la position y
μ_j	: Probabilité du $j^{\text{ème}}$ modèle de mouvement
Λ	: La fonction de maximum vraisemblance

INTRODUCTION

Ce chapitre introductif à notre mémoire a une double finalité. La première est de préciser le cadre de la thèse et le problème qu'on se propose de résoudre. Tandis que la seconde consiste à présenter les principales contributions de ce travail en indiquant le fil directeur reliant ces deux parties.

1. Problématique

La poursuite multi-cibles a pour objet le suivi d'un ensemble de cibles mobiles à partir des données obtenues séquentiellement. Ce problème est particulièrement complexe du fait du nombre inconnu et variable de cibles, de la présence de bruit de mesure, d'incertitude de détection et d'incertitude dans l'association de données rend le traitement de ce problème assez ardu. D'une manière générale, la poursuite multi-cibles s'articule autour des aspects suivants :

- Observations : c'est l'ensemble des mesures reçues par le capteur (radar, sonar, caméra, etc..). Celles-ci dépendent des paramètres intrinsèques de la cible (appelés état de la cible), de son environnement et du bruit de mesure.
- Association de données : lorsque le nombre de cibles observées augmente, le capteur reçoit alors des mesures mélangées qu'il va falloir associer aux cibles correspondantes.
- Règle de décision : c'est le critère ou méthode que nous utilisons pour obtenir une estimation de l'état de la cible à partir des observations reçues.

La poursuite d'une cible consiste généralement en l'estimation de certains paramètres qui décrivent le mouvement de la cible à partir des mesures reçues. Cette estimation devient compliquée lorsque le nombre de cibles augmente, ceci illustre la difficulté de la poursuite multi-cibles. Celle-ci est liée au problème d'association de données, donc la qualité de la poursuite multi-cibles dépend essentiellement de la bonne association de données.

Le problème de l'association de données dans la poursuite multi-cibles a été largement traité dans la littérature [1-4], nous pouvons citer à titre d'exemple :

- la méthode du plus proche voisin (en anglais « nearest neighbor » (NN)) [1].
- La méthode d'association probabiliste des données conjointes (en anglais « joint probabilistic data association » (JPDA)) [2].
- Le filtre de poursuite à hypothèses multiples (en anglais « multiple hypothesis tracking filter » (MHT)) [3].
- La méthode d'association par les ensembles floue (en anglais « Fuzzy set » (FS)) [4].

L'un des inconvénients majeurs de ces techniques réside dans l'exigence de la connaissance parfaite des probabilités, et plus particulièrement de la probabilité a priori, qui n'est pas connue avec certitude lorsque les données du problème sont imparfaites.

2. Motivation

Ce travail trouve son origine et sa motivation dans le besoin d'optimiser la poursuite multi-cibles pour pallier aux limitations des méthodes d'association de données. Ces limitations nous ont amenés à explorer une approche basée sur une théorie récente qui permet de gérer aussi bien les données incertaines que celle imprécise. Cette théorie est appelée théorie de 'Dempster-Shafer'.

Après les travaux de Dempster, Shafer a proposé une nouvelle approche qui a été appelée : théorie de Dempster-Shafer, ou théorie de l'évidence, cette théorie est une généralisation de la théorie bayésienne. À partir du formalisme mathématique développé, Shafer a montré l'intérêt des fonctions de l'évidence pour la modélisation de connaissances incertaines. En effet, cette théorie permet de gérer les situations d'ignorance. La modélisation des informations se fait à l'aide de fonctions de l'évidence. Une fois les fonctions de l'évidence obtenues, la fusion est réalisée par l'intermédiaire de la règle de combinaison de Dempster (dans le présent travail, nous avons ramené le problème de l'association de données à un problème de fusion de données dans le cadre de la théorie de l'évidence). L'utilisation de cette théorie ne nécessite pas de connaissance a priori sur le problème à traiter.

La difficulté de mise en œuvre de la théorie de l'évidence se situe au niveau de l'obtention des fonctions de l'évidence, car il n'existe pas de méthodes spécifiques pour résoudre ce problème. Dans la plupart des cas, la modélisation utilisée dépend de l'application envisagée [5]. La théorie de l'évidence trouve son application dans plusieurs domaines exploitant les avantages de cette théorie [6] :

- La fusion multi capteurs.
- Le diagnostic, la classification et la combinaison de classifieurs.
- Le traitement d'image.
- La reconnaissance des formes.
- La surveillance de l'environnement.

3. Objectifs et Contributions

L'objectif principal est d'utiliser la règle de combinaison des évidences dans la théorie de Dempster-Shafer pour résoudre le problème d'association de données. Plus précisément, le travail de ce mémoire de magister se situe au carrefour des deux grands axes suivants dans le contexte de poursuite multi-cibles :

- Les cibles ne changent pas leurs modèles de mouvement
 Nous allons étudier les performances de la poursuite des cibles qui ne changent pas leurs modèles de mouvement en utilisant la méthode d'association de données par la combinaison de Dempster et d'autres méthodes d'association de données NN et JPDA. La poursuite est effectuée par le filtre de Kalman pour la prédiction et l'estimation des états de cibles avec ou sans la présence d'un clutter (fouillis) de surface. Nous évaluons ces performances en termes de trajectoires estimées, la probabilité de la bonne association et l'erreur quadratique moyenne en position et en vitesse.
- Les cibles changent leurs modèles de mouvement
 Nous effectuons une étude sur les performances de la poursuite des cibles qui changent leurs modèles de mouvements et la classification de mouvements en utilisant la méthode d'association de données par la combinaison de Dempster et d'autres méthodes d'association de données NN et JPDA. Nous utilisons des modèles multiples interagissant à base de filtre de Kalman étendu avec ou sans la présence d'un clutter (fouillis) de surface. Nous évaluons ces performances en

termes de trajectoires estimés, la probabilité de bonne association, la probabilité de classification de mouvement et l'erreur quadratique moyenne en position et en vitesse.

4. Organisation du mémoire

Nous avons voulu présenter un exposé vivant, clair et illustré par de nombreux figures et algorithmes. Ce document est constitué de la présente introduction, de quatre chapitres illustrant les différents aspects de nos travaux et d'une conclusion. Nous avons ajouté, en début de chaque chapitre, une introduction détaillant plus encore le contexte et les enjeux de la partie traitée dans le dit chapitre, ainsi que les travaux effectués. Chaque chapitre se termine par une simulation numérique avec des interprétations des résultats obtenues. Plus précisément, ce rapport de thèse est organisé comme suit :

- Dans le Chapitre 1, nous présentons des généralités sur la poursuite des cibles.
- Ensuite, dans le chapitre 2 nous exposons la théorie de Dempster-Shafer, qui permet de modéliser et de combiner des informations imparfaites. En particulier nous mettons l'accent sur la combinaison de Dempster qui représente l'association de données dans la poursuite multi-cibles.
- Par la suite, dans le chapitre 3 nous étudions les performances de la poursuite des cibles non manœuvrantes en utilisant le filtre de Kalman. Nous comparons les performances de poursuite de la méthode d'association de données par combinaison de Dempster et la méthode d'association de données NN et JPDA avec et sans la présence de clutter (fouillis) selon plusieurs critères.
- Puis, dans le chapitre 4, nous abordons la poursuite et la classification de mouvements des cibles manoeuvrantes en utilisant des modèles multiples interagissant à base de filtre de Kalman étendu. Nous comparons les performances de la poursuite et la classification de mouvements de cibles obtenues dans le cadre de la théorie des évidences à celles obtenues en utilisant les NN et JPDA.
- À la fin de ce manuscrit, une conclusion vient résumer les apports essentiels du présent travail ainsi que les directions futures de recherche que nous envisageons.

CHAPITRE 1

GENERALITES SUR LA POURSUITE DES CIBLES

1.1. Introduction

La poursuite de cible (Target tracking) est un domaine très large dont l'objectif est de suivre le mouvement d'un mobile dans l'espace défini par la zone de perception d'un ou plusieurs capteurs.

La poursuite intervient donc après une phase de détection de mouvement. Elle fait appel à plusieurs domaines de traitement du signal et d'automatique :

- Le traitement d'image et/ou le traitement de signal acoustique, selon le mode de perception utilisé (vision, acoustique, radar).
- Le filtrage pour éliminer le bruit sur les mesures des positions de la cible effectuées et prédire la trajectoire.
- La fusion de capteurs, car suivre un mobile avec un seul capteur est difficilement réalisable, il faut envisager des capteurs de résolutions et de natures différentes collaborant entre eux.
- L'automatique pour asservir les capteurs mobiles à suivre la trajectoire d'une cible.

Depuis plusieurs années, ce domaine de recherche a attiré l'attention de nombreuses personnes et plusieurs algorithmes d'estimation de trajectoire d'une cible sont apparus. L'intérêt tient à la diversité des applications, essentiellement militaires :

- Détection et poursuite de missiles balistiques (les données utilisées sont alors des images infrarouges fournies par des satellites de surveillance).
- Poursuite de missiles conventionnels (anti-missiles) ou d'aéronefs.
- Perception des obstacles ou des objectifs environnant un véhicule automatisé en mouvement.
- Surveillance de zone (parking,...).
- Dans des applications météorologiques (calcul de la vitesse et de l'orientation des vents).

1.2. Le suivi de cibles

Le rôle du pistage de cible est d'assurer la cohérence temporelle des observations afin d'éviter les fausses alarmes et de filtrer l'état. La structure d'un tel système est représentée dans la figure (1.1). Les capteurs délivrent des signaux qui sont collectés par un module de traitement de signal qui délivre à son tour des mesures au module de traitement des données. Les pistes sont des éléments du sous-système de traitement des données dont le rôle est de former et de maintenir les pistes.

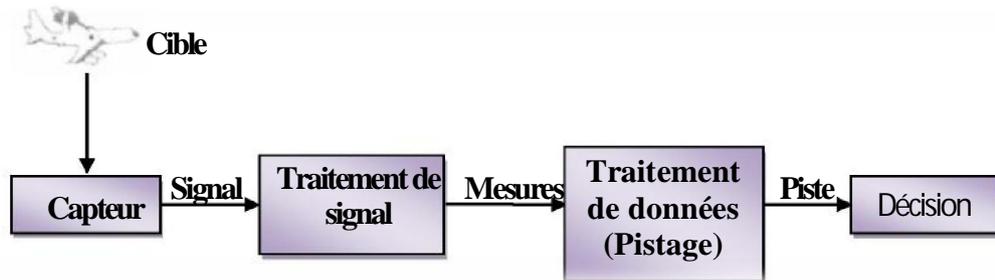


Figure 1.1 : Structure d'un système de surveillance

Le suivi de cibles est un élément indispensable pour un système de détection cible, son rôle est de déterminer le nombre, la position et le mouvement des différentes pistes [7].

Un système de pistage repose sur plusieurs modules dont le principal est celui qui permet une estimation récursive de l'état de la piste (position, vitesse, accélération). Ce module s'appuie sur une méthode de filtrage (dans ce mémoire on a utilisé le filtre de Kalman étendu EKF). D'autres modules comme l'initialisation, la destruction, l'association des pistes sont indispensables au bon fonctionnement (voir figure (1.2)).

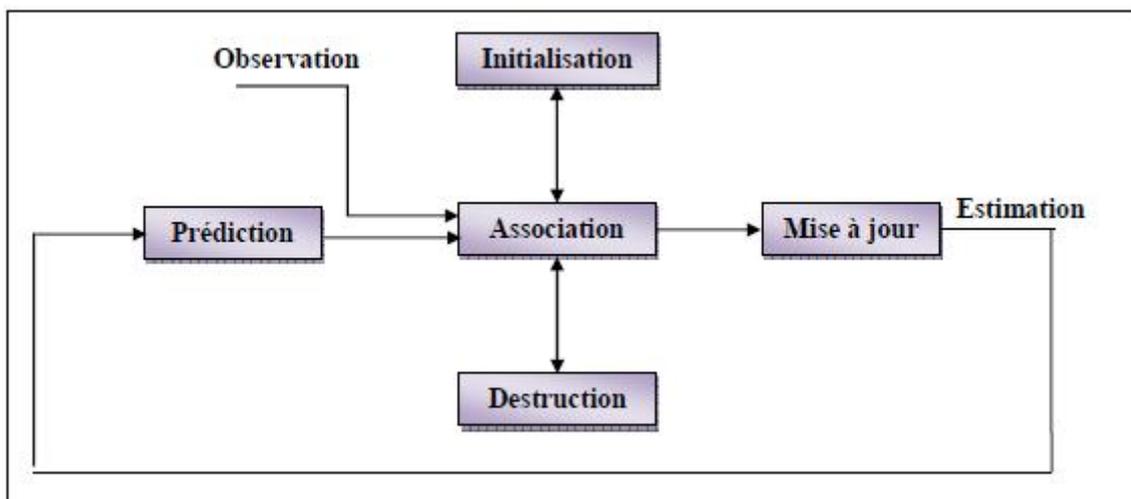


Figure 1.2 : Le module de pistage

En effet toutes les mesures délivrées par les capteurs ne sont pas forcément des mesures provenant de cibles, mais peuvent provenir d'interférences aléatoires (condition atmosphérique, fausses alarmes...). Il est donc nécessaire de valider les mesures qui correspondent le mieux à l'estimation : c'est l'association.

Une piste tentée est issue d'une mesure non associée avec les pistes existantes. Une piste sera confirmée lorsque le nombre de mis à jours effectuée se fait pendant un temps fixe : c'est l'initialisation.

Une piste est dite supprimée si elle n'est pas mise à jour par une mesure pendant un laps de temps fixe : c'est la destruction.

1.3. Types de cibles

Selon la manoeuvrabilité des cibles, on peut distinguer deux types de cibles :

- Cibles non manoeuvrantes (Figure 1.3 (a)) : la cible suit une trajectoire rectiligne à vitesse constante sans changement brusque de mouvement.
- Cibles manoeuvrantes (Figure 1.3 (b)) : la cible peut à tout moment subir un changement de mouvement (accélération, décélération, virage).

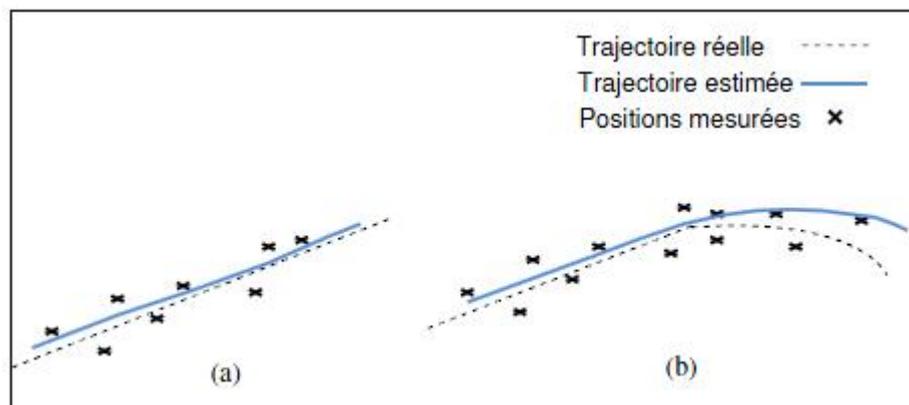


Figure 1.3 : Cibles (a) non manoeuvrantes (b) manoeuvrantes

1.3.1. Cibles non manoeuvrantes

Dans le cas de cibles non manoeuvrantes, par exemple des avions de l'aviation civile volant suivant des trajectoires rectilignes, le système peut être décrit par exemple par l'équation [8]:

$$dx_t = Fx_t dt + Gdv_t \quad (1.1)$$

Où $\{Xt\}$ désigne le processus état du mobile (typiquement position, vitesse,...) de son centre de gravité) et $\{Vt\}$ un bruit d'état, F est la matrice de transition, G permet de lier le bruit de modélisation Vt au vecteur d'état.

Les mesures Zt (capteurs radar, infrarouge,...) servent à estimer X par l'espérance conditionnelle $\hat{x}_t = x_t | z_t$ qui minimise l'erreur quadratique moyenne $E = \{\hat{x}_t^T \hat{x}_t | Z_t\}$ avec $\hat{x}_t^T = x_t - \hat{x}_t$.

Un filtre de Kalman classique est en général suffisant pour effectuer la poursuite de telles cibles.

1.3.2. Cibles manoeuvrantes

Dans le cas de cibles manoeuvrantes [9], l'accélération du mobile comporte alors, en plus de fluctuations autour d'une moyenne nulle, une partie quasi discontinue et non linéaire correspondant aux manoeuvres commandées par le pilote. L'apparition soudaine de ce terme commandé appelle une augmentation de la bande passante du pisteur afin de ne pas laisser croître l'erreur, induire un traînage et risquer de décrocher. Le modèle doit alors être complété par un terme discret [8] [10] :

$$dx_t = Fx_t dt + Gdv_t + b_\phi(x_t)d\phi_t \quad (1.2)$$

Où x_t est le vecteur d'état, F est la matrice de transition, G est le gain de recalage optimal (au sens de l'erreur quadratique moyenne), v_t est le bruit d'état. ϕ est un processus ponctuel ($d\phi_t = 0$ sauf aux instants de manoeuvres) et $b_\phi(x_t)$ relie les sauts de ϕ aux manoeuvres considérées [8].

Dans ces conditions, un filtre de Kalman est insuffisant, on doit faire des changements sur les paramètres du filtre pour s'adapter au modèle de mouvements de la cible pour pouvoir suivre avec précision les trajectoires des cibles. La description de cette adaptation fait l'objet des paragraphes suivants.

1.4. Adaptation à la manœuvre

Une fois qu'une manœuvre est détectée dans la trajectoire de la cible, une adaptation se porte généralement sur les paramètres du filtre. Cette adaptation s'effectue selon le modèle adopté du mouvement de la cible.

L'accélération peut être modélisée par une variable aléatoire ou déterministe, pour cela, quatre grandes approches sont proposées pour adapter les paramètres du filtre de poursuite à la nouvelle situation (présence de manœuvre). Cette adaptation est faite pour réduire les erreurs de prédiction et d'estimation de l'état de la cible (position et vitesse).

1.4.1. Approche basée sur le changement des paramètres de poursuite

Dans cette approche, l'accélération est considérée comme un bruit gaussien de moyenne nulle et de matrice de covariance Q , et qui vient perturber le mouvement des cibles considéré uniforme (vitesse constante). Le principe de cette approche est l'utilisation de plusieurs fenêtres de corrélation, dont la dimension correspond à un degré de manoeuvrabilité figure (1.4). Les paramètres du filtre de poursuite sont ajustés en fonction des paramètres statistiques de l'accélération (moyenne et covariance Q) correspondant à la fenêtre dans laquelle le plot radar associé est situé.

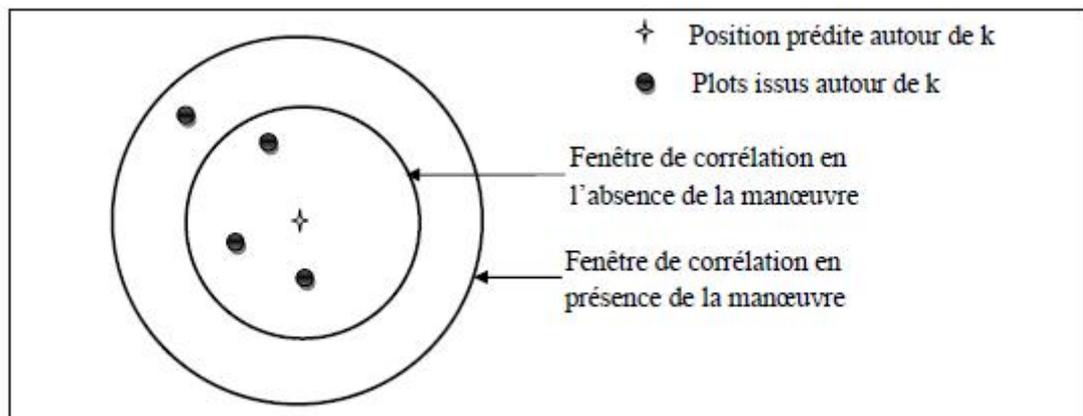


Figure 1.4 : Adaptation des dimensions de la fenêtre de corrélation

Si l'on considère que l'accélération est un bruit blanc, en l'absence de manoeuvre, le bruit est supposé au niveau Q_1 . Une fois que la manoeuvre est détectée on augmente le niveau du bruit, passant ainsi à Q_2 . Le processus similaire peut être utilisé pour diminuer le niveau du bruit à la fin de la manoeuvre.

Cette méthode peut être généralisée pour plusieurs niveaux de bruit. Ce type d'adaptation rend le filtre capable de suivre la cible dans la phase de manoeuvre, la moyenne de l'innovation diminue et tend vers zéro mais sa variance est augmentée.

1.4.2. Approche basée sur le changement de la dimension du modèle

Dans le cas général où la trajectoire de la cible est rectiligne, et le modèle d'état est à vitesse constante. Si une manoeuvre est détectée, un deuxième modèle d'état est utilisé et qui prend en considération l'accélération en plus de la position et de la vitesse. Pour remédier au problème de retard de détection, un historique des états est utilisé pour initialiser le deuxième modèle.

Une fois que le vecteur d'état est modifié, le processus de filtrage recommence à partir de l'instant $(k - s)$, comme s'est montré dans la figure (1.5).

L'approche basée sur le changement de l'ordre du modèle d'état, permet une bonne poursuite des cibles en phase de manoeuvres, et elle n'est pas très sensible au retard de détection. Son inconvénient majeur est la nécessité de mémorisation d'un nombre de paramètres important, et la nécessité d'un large temps de calcul surtout à l'instant de la détection de la manoeuvre.

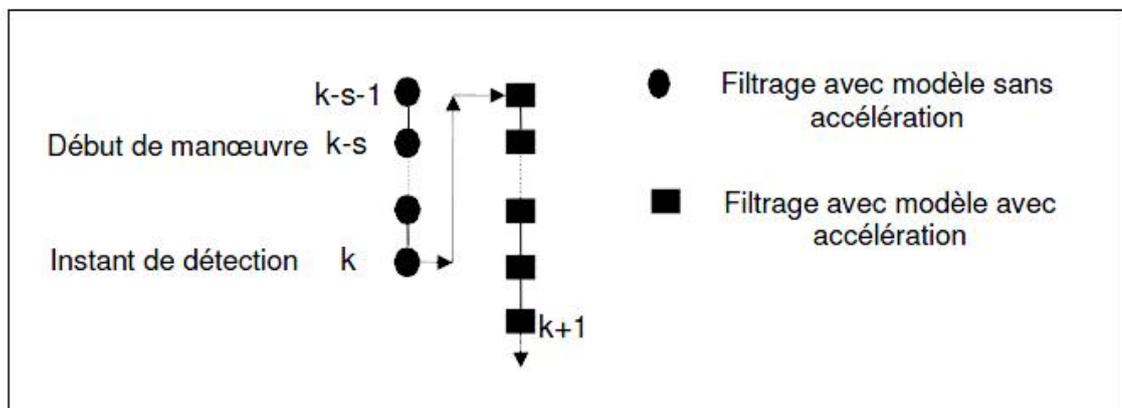


Figure 1.5 : Filtrage avec changement de la dimension du filtre

1.4.3. Approche basée sur l'estimation de l'accélération

Dans cette approche, l'accélération est considérée comme un terme additif déterministe. Son estimation se fait en utilisant la séquence de l'innovation $\{z(1), z(2), \dots, z(k)\}$.

Une fois l'accélération estimée, elle est utilisée pour corriger les estimations d'état, elle peut être aussi utilisée pour la détection de la manœuvre en évaluant le module de l'accélération estimée.

Cette méthode d'adaptation donne de bons résultats, mais elle nécessite un grand espace mémoire ainsi qu'un énorme temps de calcul. Ceci est dû au fait qu'elle estime l'accélération d'une façon non récursive.

1.4.4. Approche à Modèles Multiples

L'approche à Modèles Multiples (MM), quand nous développerons dans le quatrième chapitre, consiste à considérer que le système ne peut obéir qu'à un nombre fini de modèles distincts. De tels systèmes sont dits hybrides puisqu'ils ont à la fois des incertitudes sur l'état et des incertitudes sur le modèle. Deux grandes approches sont à considérer :

- Approche à modèle fixe

Une fois que les filtres sont initialisés avec la première mesure, ils fonctionnent récursivement sur leurs propres estimés, l'état estimé global est une combinaison linéaire de ces derniers, comme c'est montré dans la figure (1.6).

Cette approche est valide si le modèle du système ne change pas durant la période en question. Elle ne l'est plus si à un moment donné la cible manœuvre ou si le modèle de la cible ne se trouve pas parmi les candidats.

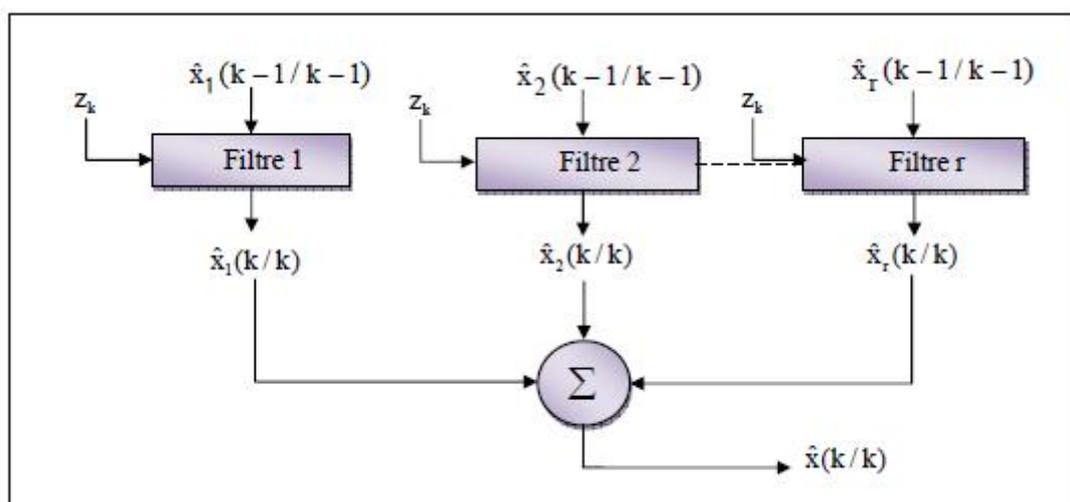


Figure 1.6 : Schéma bloc d'un système MM

- Approche à changement de modèle

Pour s'affranchir de la première hypothèse, on peut estimer l'état de la cible pour toutes les suites possibles de modèles. Supposons que l'on ait m modèles durant k échantillons, il faut calculer un estimé de l'état pour les m^k historiques de modèles possibles. Le problème de cette approche est qu'elle induit une croissance exponentielle du nombre d'historiques à considérer. On ne peut passer en outre à cette augmentation que par l'utilisation de techniques sous optimales (Pseudo-Bayésiennes Généralisées), Modèles Multiples Interactifs illustrée dans la figure (1.7).

Ces algorithmes sous optimaux ne nécessitent pas l'étape de détection de la manoeuvre, mais pour couvrir toutes les manoeuvres imaginables, il leurs faut un grand nombre de filtres différents, induisant ainsi une charge de calcul énorme.

Ces approches demandent une connaissance à priori sur les manoeuvres de la cible, elles fonctionnent relativement bien tant que les manoeuvres obéissent aux hypothèses énoncées, mais leurs performances sont gravement diminuées dès que la cible effectue une manoeuvre dont les caractéristiques n'ont pas été prévues.

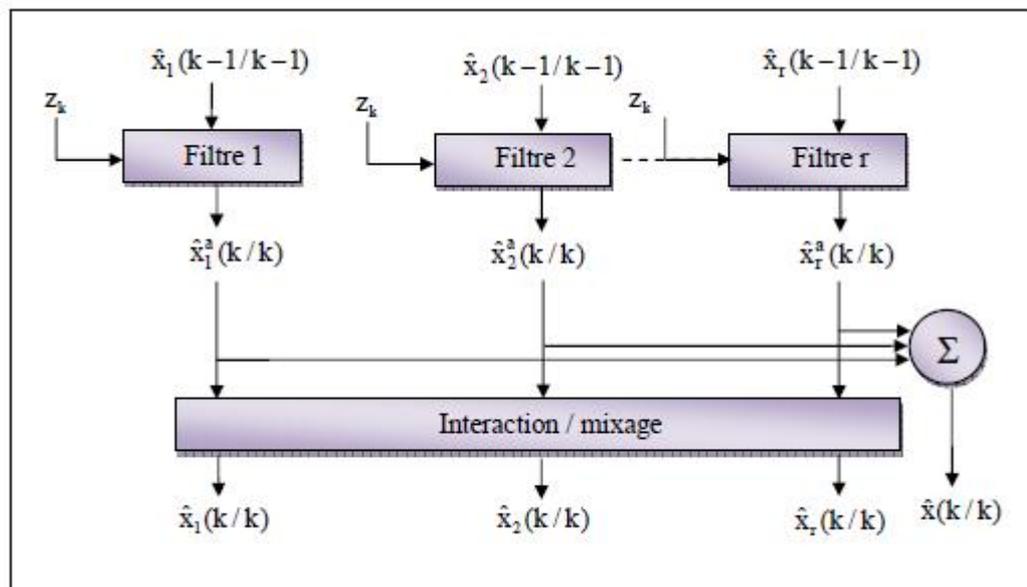


Figure 1.7 : Schéma bloc du système à Modèles Multiples Interactifs (IMM)

Cependant, lors de la poursuite de plusieurs cibles à la fois ou poursuite d'une cible se trouvant dans un environnement qui contient des fausses alarmes, une autre opération doit être également effectuée par le système de poursuite, à savoir l'association des différentes données ou mesures reçues des différentes cibles traquées.

1.5. Description d'un système de poursuite multi-cibles

1.5.1. Description

Les algorithmes de poursuite cherchent en général à maintenir une liste de pistes, c'est-à-dire une liste de cibles en cours de poursuite. Le processus de déroulement est présenté dans la figure (1.8).

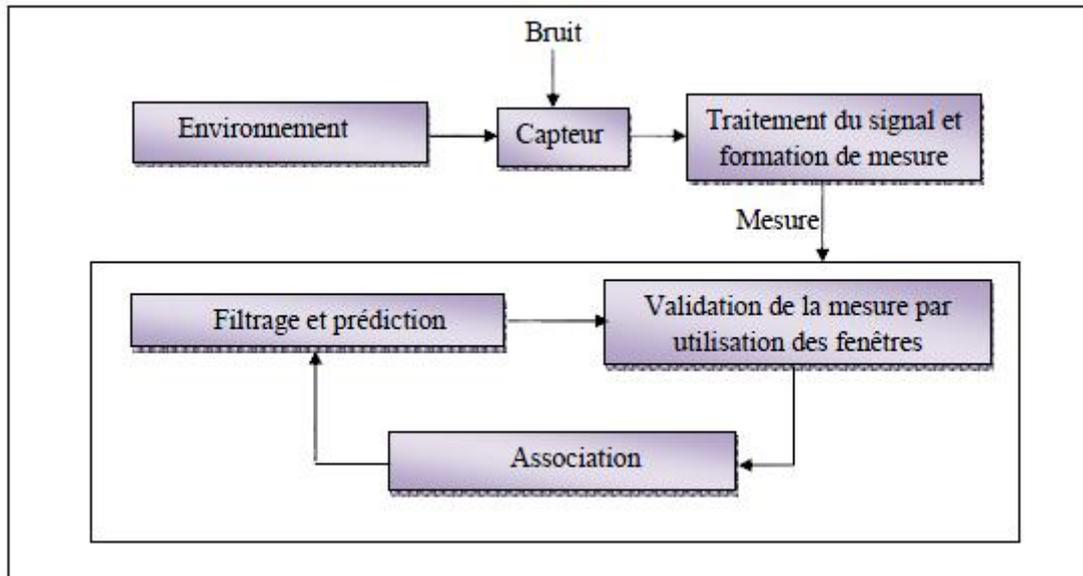


Figure 1.8 : Schéma synoptique d'un algorithme de poursuite

L'information est reçue par un capteur, les incertitudes de ce dernier en plus des facteurs perturbateurs extérieurs sont modélisées comme un bruit additif. Le signal récupéré de ce capteur sera traité pour une éventuelle conversion de mesures, celles-ci deviendront les données d'entrée du système de poursuite. Lorsqu'une nouvelle série de mesures est disponible, la première tâche à réaliser sera d'associer ces dernières aux pistes maintenues. Cette tâche peut être explicitée en trois phases [7]:

1. Premièrement une phase de fenêtrage, qui a pour but de simplifier la phase d'association, telle qu'une observation issue d'un capteur pourra être considérée comme une information provenant de la cible d'intérêt, si sa distance par rapport à l'état prédit de l'objet est inférieure à un seuil donné. La fenêtre de validation doit être suffisamment grande pour qu'une observation provenant d'une cible s'y trouve et suffisamment petite pour pouvoir filtrer efficacement les observations indésirables.

2. Deuxièmement une phase d'association des mesures retenues considérées comme valides par la phase de fenêtrage avec les pistes existantes.
3. Troisièmement une phase de maintien des pistes qui nous permettra de décider si nous devons :
 - Créer de nouvelles pistes, si un nouvel objet non encore poursuivi est entré dans le champ de vue du capteur.
 - Ignorer d'anciennes pistes, si des objets poursuivis ont disparu du champ de vue du capteur.
 - Maintenir une piste existante, selon qu'une nouvelle observation lui a été attribuée ou non.

Les deux dernières phases à savoir association de la piste avec l'observation et maintien des pistes sont spécifiques à la poursuite multi-cibles, elles sont généralement résumées sous le terme d'association de données.

La dernière étape est celle du filtrage qui n'est pas spécifique à la poursuite multi-cibles, puisqu'elle consiste en la mise à jour et en la prédiction de l'état de chaque piste. Ceci est généralement fait à l'aide d'une des variantes du filtre de Kalman.

1.5.2. Validation des mesures

Généralement dans des applications de poursuite, après exécution du procédé de détection du signal de mesure, il y a un procédé qui trie les mesures et choisit celles qui seront incorporées dans l'estimateur d'état. Une fenêtre est introduite et seules les détections à l'intérieur de cette fenêtre peuvent être associées à la cible d'intérêt. Ceci est réalisé pour éviter d'assigner des mesures dans tout l'espace de mesure du capteur. Cela permet ainsi, d'une part d'éviter des calculs inutiles par les fonctions d'association et d'autre part de décider si une observation appartient à une piste déjà établie ou à une nouvelle.

Le fenêtrage est effectué pour chaque piste et à chaque instant par la définition d'une zone de surveillance appelée fenêtre (ou région d'intérêt).

L'ensemble des mesures présentes dans cette région, sont sélectionnées pour l'association, les autres sont ignorées.

La taille de la fenêtre influe sur le nombre de mesures valides. si nous choisissons une fenêtre trop petite, alors la probabilité d'éliminer la mesure provenant de la cible augmente, ce qui peut provoquer la perte de la piste. Au contraire, si la taille est trop grande, un grand nombre de mesure ne provenant pas de la piste est utilisé, cela tend à augmenter les calculs et à détériorer la précision du pistage.

Le fenêtrage est un essai brut qui permet de classifier l'observation selon l'une des catégories suivante :

- Candidate pour la mise à jour d'une poursuite : l'observation peut satisfaire la fenêtre d'une ou plusieurs pistes existantes. Dans ce cas l'observation devient candidate pour une association avec ces pistes. Notons aussi que plus d'une observation peuvent satisfaire la fenêtre néanmoins l'observation peut ne pas être utilisée pour la mise à jour de la poursuite, même si la fenêtre est satisfaite.
- Observation initiale pour le déclenchement d'une nouvelle poursuite : l'observation peut ne pas satisfaire la fenêtre d'aucune piste existante, dans ce cas elle devient une candidate immédiate pour le déclenchement d'une nouvelle poursuite de cible, ou considérer comme étant une observation indésirable.

1.6. Problèmes d'association de pistes

La principale difficulté de la poursuite multi-cible, vient du fait que nous ne savons pas associer à priori une observation provenant d'un capteur à une cible présente dans le volume d'observation de ce dernier. Cette difficulté se voit accentuée si nous considérons que le capteur peut générer des fausses alarmes, c'est-à-dire des observations ne correspondant à aucun objet existant, et que l'on ne connaît pas le nombre d'objets présent dans le volume d'observations, et si ce nombre peut évoluer au cours du temps. D'où l'application du fenêtrage qui est la première phase de résolution d'un problème d'assignement des différentes observations avec leurs pistes respectives, cependant d'autres techniques sont requises dans le cas où une observation se trouve à l'intérieur de plusieurs fenêtres de cibles poursuivies.

La figure (1.9) illustre une situation typique où un conflit d'assignement se produit.

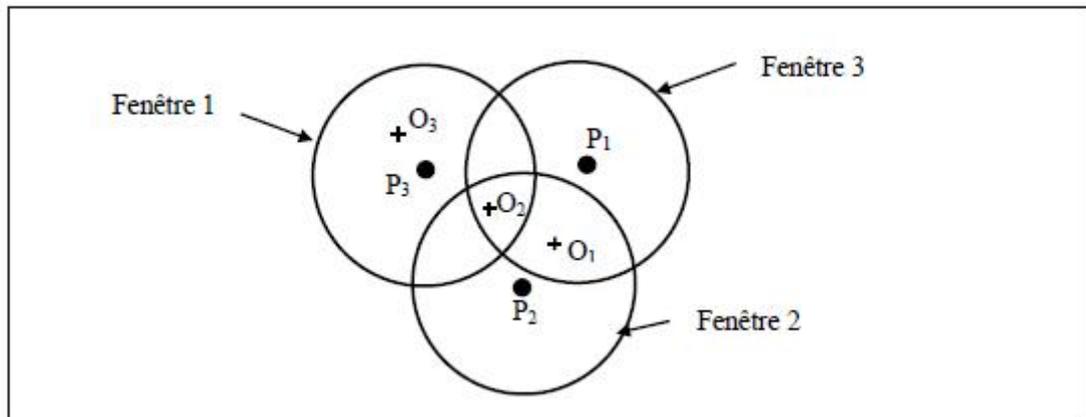


Figure 1.9 : Exemple de situation de conflit dans un problème de poursuite

Dans cette figure, O_1 , O_2 , O_3 représentent les positions des observations effectuées à l'aide de capteur, P_1 , P_2 , P_3 les positions prédites par le système de poursuite et correspondant à trois trajectoires. Les fenêtres sont représentées à l'aide de cercles centrés sur ces prédictions. On remarque que l'observation O_3 est située uniquement à l'intérieur de la fenêtre correspondant à la trajectoire N°3 et que de ce fait, il n'y a aucune situation de conflit. Par contre, l'observation O_1 est située simultanément dans les fenêtres des trajectoires N°1 et N°2, alors que l'observation O_2 est située simultanément à l'intérieur des trois fenêtres, ce qui représente dans les deux cas une situation conflictuelle.

1.7. Catégories d'association de données

1.7.1. Mesure à mesure (déclenchement de la poursuite)

Cette catégorie d'association est utilisée pour former de nouvelles tentatives de poursuites dans le cas où il y a des observations non assignées aux pistes existantes. L'objectif de l'opération d'initiation est de confirmer la détection d'une nouvelle cible se trouvant à l'intérieur du champ de couverture du capteur et permettant ainsi d'identifier les observations indésirables (clutter).

1.7.2. Mesure à une piste (mise à jour et maintien de la poursuite)

Cette opération consiste à associer à une piste donnée, une seule observation reçue parmi d'autres à un instant donné. Pour effectuer cette opération, l'utilisation d'une fenêtre générée autour de l'état prédit est nécessaire, et seules les observations se trouvant à

l'intérieur de la région formée par les différentes fenêtres des pistes existantes, seront prises en considération pour en sélectionner une seule piste existante, qui servira de mesure pour actualiser la piste correspondante.

1.7.3. Poursuite à poursuite (fusionnement de poursuite)

Le problème de l'association d'une poursuite à une poursuite, surgit dans le cas d'un système doté d'un réseau de capteurs où chaque capteur dispose de son propre système de traitement de l'information et de son propre ensemble de cibles lors de la poursuite.

1.8. Conclusion

Ce chapitre a été consacré à des généralités sur la poursuite des cibles, nous avons commencé par une définition de la poursuite, ensuite nous avons décrit les types de cibles puis nous avons donné un ensemble d'approches d'adaptation des paramètres du filtre de poursuite, en dernier point nous avons parlé d'une étape importante de la poursuite qui est l'association de données utilisée lorsque il ya plusieurs cibles.

CHAPITRE 2

ASSOCIATION DE DONNÉES PAR LA THÉORIE DE DEMPSTER-SHAFER

2.1. Introduction

La poursuite multi-cibles est un domaine vital pour la sécurité aérienne qui nécessite une grande précision et une continuité dans le traitement. La qualité de la poursuite repose sur la bonne association de données. Pour cela, dans notre travail nous avons exploité une théorie récente [11], connu pour son efficacité dans la combinaison et la modélisation des données imprécises. Cette théorie est appelée théorie de “Dempster-Shafer”.

Cette méthode a été utilisée durant les années 80 dans la modélisation des incertitudes dans les systèmes experts et durant les années 90 dans la fusion d’informations (télédétection, identification de cibles, imagerie médicale, dans...). Cette théorie est une généralisation de la théorie bayésienne. Elle a été introduite par Shafer [12], mais les origines de la théorie remontent à Dempster [13], par ses travaux sur les bornes inférieure et supérieure d’une famille de distributions de probabilités. À partir, du formalisme mathématique développé, Shafer a montré l’intérêt des fonctions de l’évidence pour la modélisation des connaissances incertaines [14]. En effet, cette théorie permet de gérer les situations d’ignorance ; Dans ce chapitre, nous commençons par présenter la théorie de l’évidence et ses différentes fonctions de masse ensuite nous abordons la combinaison des évidences dans la théorie de “Dempster-Shafer” puis nous décrivons la règle de décision pour prendre la bonne combinaison. Par la suite, nous évaluons les performances de notre méthode dans la poursuite multi-cibles et l’association de données pour différents scénarios. Suite à cette évaluation, une conclusion sera donnée.

2.2. Théorie de Dempster-Shafer

La théorie de Dempster-Shafer (DST) ou théorie de l'évidence est souvent considérée comme une généralisation de la théorie bayésienne des probabilités [12], [15]. La théorie de Dempster-Shafer a été introduite par le biais des notions de probabilités supérieures et inférieures par Dempster [13]. Elle a ensuite été affinée et présentée par Shafer par le biais des fonctions de croyances et de plausibilité [12].

Les applications ne concernent que des ensembles de définitions discrets au niveau crédal et pignistic. Elles sont articulées autour d'une distribution de masse d'évidence m défini sur l'ensemble des propositions Θ (espace de mondes possibles de cardinal fini). Elles associent des degrés de croyance et de plausibilité à des parties de A (groupe de propositions ou d'informations) de Θ .

2.2.1. Cadre de discernement

La DST nécessite la définition d'un cadre de discernement noté Θ , constitué de l'ensemble de toutes les hypothèses nécessaires à la description complète d'une situation présente. Les hypothèses de l'ensemble sont supposées exclusives. Aussi, l'ensemble est considéré comme étant exhaustif (hypothèse du monde fermée) [16]. Généralement, le cadre de discernement Θ définit les hypothèses pour lesquelles les sources d'informations fournissent des confidences. Pour un ensemble incluant H_N hypothèses simples possibles dans un contexte précis, le cadre de discernement peut être défini comme suit :

$$\Theta = \{H_1, H_2, \dots, H_n, \dots, H_N\} \quad (2.1)$$

Le cadre de raisonnement utilisé dans la DST est le cadre de raisonnement de base noté 2^Θ , qui se définit comme étant l'ensemble de tous les sous-ensembles possibles composés à partir des hypothèses simples d'un cadre de discernement Θ qui permet l'union. On désigne le cadre de raisonnement 2^Θ comme étant l'ensemble de puissance, qui est une version étendue du cadre de discernement où il contient non seulement des hypothèses simples (singletons), mais aussi toute union de singletons (hypothèses composées) [12] :

$$2^\Theta = \{\emptyset, H_1, H_2, \dots, H_N, H_1 \cup H_2, \dots, H_1 \cup H_2 \dots H_N\} \quad (2.2)$$

Ainsi, on retrouve dans l'ensemble 2^Θ : l'ensemble vide (\emptyset), les hypothèses simples H_i , et les hypothèses composées obtenues par les unions des hypothèses simples, qui représentent des ignorances ou l'incapacité à différencier les différentes hypothèses simples.

2.2.2. Fonction de masse élémentaire

Soit Θ un cadre de discernement, nous définissons une fonction de masse m comme :

$$m : 2^\Theta \rightarrow [0,1] \quad (2.3)$$

Cette fonction vérifie les propriétés suivantes :

$$\begin{aligned} m(\emptyset) &= 0 \\ m(A) &\in [0, 1] \\ \sum_{A \subseteq \Theta} m(A) &= 1 \end{aligned} \quad (2.4)$$

La fonction de masse élémentaire d'un ensemble est utilisée pour exprimer un degré de confiance (niveau de croyance) accordé à cet ensemble. Dans la DST, la fonction de masse m est définie pour chaque ensemble A du cadre de raisonnement 2^Θ ($A \in 2^\Theta$), répondant à deux exigences : respect de l'hypothèse du monde fermé où la masse de l'ensemble vide doit être nulle, et la somme des masses de tous les ensembles possibles A est égale à 1.

La quantité $m(A)$ est la part de croyance placée strictement sur A sans que celle-ci puisse être répartie sur les hypothèses qui la composent. La quantité se différencie d'une probabilité par le fait que la totalité de la croyance est répartie non seulement sur les hypothèses singletons H_n , mais aussi sur les hypothèses composites A . On peut alors accorder une partie de la croyance à une proposition et affecter à l'ensemble des hypothèses contenues dans la proposition une croyance à la réalisation de chacune d'entre-elles sans prendre parti pour l'une d'elles précisément.

Nous présentons ici quelques fonctions de masse particulières qui vont être utiles dans la modélisation des informations [6].

- Élément focale :

Nous notons par F l'ensemble d'éléments focaux de la fonction de masse m .

$$F = \{A \in 2^\Theta \mid m(A) > 0\} \quad (2.5)$$

Un élément focal est un sous-ensemble A de Θ dont la masse $m(A)$ est non nulle.

- Fonction d'ignorance totale [6] :

Définie par :

$$m(\Theta) = 1 \quad (2.6)$$

C'est le cas de l'indétermination ou de l'ignorance totale. L'observateur sait que l'hypothèse solution se trouve dans le cadre de discernement, mais il ne peut pas en dire plus. Il est incapable de répartir sa connaissance sur un ensemble plus petit que Θ .

- Fonction de certitude totale :

Définie par :

$$m(H_n) = 1 \quad (2.7)$$

La répartition de la masse de croyance est concentrée sur une hypothèse singleton. L'observateur est sûr de connaître l'hypothèse solution, et modélise sa connaissance par une masse de croyance totale en l'hypothèse H_n .

2.2.3. Les fonctions de crédibilité et de plausibilité

Dans l'approche bayésienne, l'incertitude concernant un évènement est mesurée par une valeur unique : la probabilité, et l'imprécision concernant l'incertitude de mesure sont supposées être nulles. Dans la DST, la valeur de croyance (la crédibilité) de l'ensemble A peut être interprétée comme la valeur d'incertitude minimale autour de A , et sa valeur de plausibilité peut être interprétée comme la valeur d'incertitude maximale de A . alors, l'incertitude autour de A est représentée par des valeurs de l'intervalle $[Bel(A), Pl(A)]$, qui est appelé intervalle de confiance, où Bel représente la fonction de croyance (Belief en anglais) ou crédibilité et Pl la fonction de plausibilité. La longueur de cet intervalle quantifie l'imprécision concernant l'incertitude de la source sur l'ensemble A .

- La fonction de Crédibilité

La croyance accordée à un sous-ensemble A de Θ représente la confiance totale dont le sous-ensemble A peut bénéficier. La fonction de crédibilité, $Bel : 2^\Theta \rightarrow [0,1]$, elle peut être définie à partir de la fonction masse par :

$$Bel(A) = \sum_{B \subseteq A} m(B) \quad \forall A \subseteq \Theta \quad (2.8)$$

$Bel(A)$ représente l'ensemble de la croyance apportée aux éléments de la disjonction d'hypothèses A .

- La fonction de Plausibilité

La fonction de plausibilité, $Pl : 2^\Theta \rightarrow [0,1]$, représente la borne supérieure jusqu'à laquelle on considère un sous-ensemble A de Θ crédible, et elle peut être définie à partir de la fonction de masse par :

$$Pl(A) = \sum_{(A \cap B) \neq \emptyset} m(B) \quad \forall A \subseteq \Theta \quad (2.9)$$

$Pl(A)$ s'interprète comme la part de croyance qui pourrait potentiellement être allouée à A , c'est-à-dire toute l'information contenue dans les sous-ensembles ayant une intersection non nulle avec A .

- Relation entre la fonction de crédibilité et la fonction de plausibilité

La plausibilité de A est également reliée à la crédibilité du complémentaire de A . Elle correspond à toute l'information ne créditant pas la véracité du complémentaire de A . elle peut être définie par :

$$Pl(A) = 1 - Bel(\bar{A}) \quad (2.10)$$

Dans la théorie de Dempster-Shafer, on peut interpréter l'intervalle défini par $[Bel(A), Pl(A)]$ comme un encadrement de la probabilité réelle de A . $Bel(A)$ est « la probabilité basse » et $Pl(A)$ est « la probabilité haute ». La distribution de masse de croyance m et la fonction de crédibilité Bel sont deux représentations équivalentes d'une même information.

- Interprétation des fonctions de plausibilité et de crédibilité

Nous pouvons représenter ces deux mesures (crédibilité et plausibilité) par la figure (2.1). Cette figure explicite les appellations de vraisemblance minimale et maximale dont nous affectons parfois la crédibilité et la plausibilité dans le cadre de la théorie de l'évidence. Nous visualisons sur cette figure le fait que la crédibilité regroupe toutes les masses des éléments focaux (B_1, B_2) inclus dans le sous-ensemble A , alors que la plausibilité correspond à toutes les masses en intersection (B_1, B_2, B_3) avec le sous-ensemble considéré A .

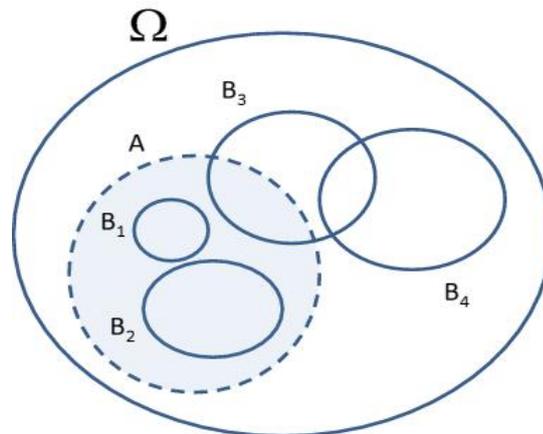


Figure 2.1 : Crédibilité et plausibilité d'un ensemble A

Dans le cadre de ce travail, $Bel(A)$ et $Pl(A)$ peuvent être vues respectivement comme une probabilité basse et une probabilité haute [16]. Il faut noter qu'il existe d'autres fonctions symétriques de la crédibilité et de la plausibilité, à savoir *l'incrédulité* $Pl(\bar{A})$ (la crédibilité du contraire) et *le doute* $Bel(\bar{A})$ (la quantité de masse de croyance restante). Les relations existantes entre ces différentes mesures sont représentées dans la figure (2.2).

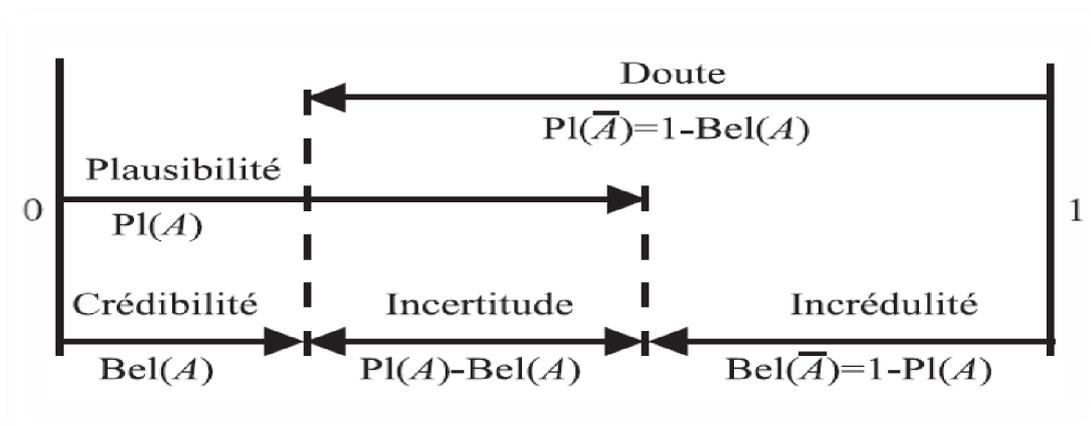


Figure 2.2 : Représentation d'évidence d'un ensemble A

2.2.4. Autres mesures de la fonction de masse

À partir de l'affectation des masses, nous pouvons citer d'autres mesures comme la fonction de communalité ou fonction interchangeabilité, $Q: 2^\Theta \rightarrow [0,1]$, elle peut être définie à partir de la fonction de masse par :

$$Q(A) = \sum_{A \subseteq B} m(B) \quad \forall A \subseteq \Theta \quad (2.11)$$

Il existe une bijection entre les fonctions m , Bel , Pl et Q comme montre la figure (2.3). En particulier, la fonction de masse est retrouvée à partir d'une fonction de croyance par la transformation de Möbius, définie par :

$$m(A) = \sum_{B \subseteq A} (-1)^{|A-B|} Bel(B) \quad (2.12)$$

$|A - B|$ représente le nombre d'éléments de A qui ne font pas partie de B .

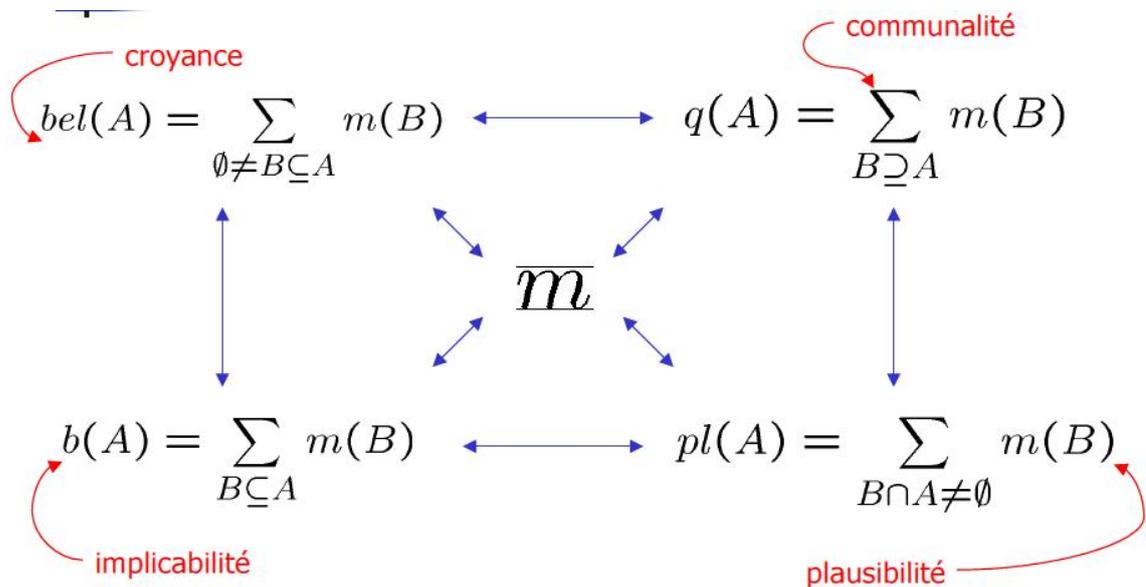


Figure 2.3 : Différentes mesures de fonction de masse [17]

2.3. Règles de combinaison

La théorie de Dempster-Shafer permet de combiner des informations issues de sources différentes, car d'après Shafer, si deux fonctions d'évidence sont définies sur le même cadre de discernement alors ce cadre de discernement distingue l'interaction pertinente entre deux informations. La combinaison des évidences intervient lorsque l'on dispose de nouvelles informations codées sous forme de BF qu'il faut fusionner avec les BF déjà existantes. La fusion d'informations se présente comme une solution permettant d'accéder à une information plus fiable.

2.3.1. Règles de combinaisons de base

Soient S_1 et S_2 deux sources d'informations indépendantes. Ces sources sont supposées totalement fiables. Les informations obtenues via ces sources sont modélisées à l'aide de fonctions de croyance appelées respectivement m_1 et m_2 . Notons m_\cap la fonction de croyance résultant de la combinaison conjonctive de m_1 et m_2 :

$$m_\cap = m_1 \cap m_2 \quad (2.13)$$

- Combinaison conjonctive

La combinaison conjonctive est une règle de combinaison élémentaire structurée sur l'opérateur d'intersection. Elle consiste à prendre les sommes de toutes les possibilités de conjonction entre toutes les sources [18].

$$m_\cap(A) = \sum_{B \cap C = A} m_1(B) m_2(C) \quad \forall A \subseteq \Theta \quad (2.14)$$

Nous pouvons généraliser cette règle à J sources d'information produisant J BF. En notant $m_\cap = \cap_{j=1}^J m_j$, nous aurons :

$$m_\cap(A) = \sum_{A_1 \cap \dots \cap A_J = A} \left(\prod_{j=1}^J m_j(A_j) \right) \quad \forall A \subseteq \Theta \quad (2.15)$$

- Combinaison disjonctive

La combinaison disjonctive est une règle de combinaison élémentaire articulée sur l'opérateur d'union. Elle consiste à prendre les sommes de toutes les possibilités de disjonction entre toutes les sources [18]. Pour la combinaison de J sources, cette règle est donnée par l'équation suivante :

$$m_{\cup}(A) = \sum_{A_1 \cup \dots \cup A_J = A} \left(\prod_{j=1}^J m_j(A_j) \right) \quad \forall A \subseteq \Theta \quad (2.16)$$

D'une façon générale, la règle de combinaison de base produit une fonction de masse non normalisée, c'est-à-dire que $m_{\cap}(\emptyset) \neq 0$. Cette hypothèse n'est pas possible dans le cas du monde fermé (paragraphe 2.2.1). Il est donc nécessaire d'introduire une étape de normalisation. Cette loi de combinaison conjonctive normalisée est plus connue sous le nom de règle de combinaison de Dempster.

2.3.2. Règle de combinaison de Dempster

La théorie de Dempster-Shafer (DST) suppose que les sources d'information sont mathématiquement indépendantes. La règle de combinaison de Dempster est en réalité une règle de combinaison conjonctive normalisée fonctionnant sur l'ensemble de puissance 2^{Θ} [19].

Elle travaille sous la contrainte du monde fermé où la masse de l'ensemble vide est supposée être nulle. Par conséquent, si la règle conjonctive génère une masse non nulle pour l'ensemble vide, cette masse est attribuée à la masse de conflits, la règle de Dempster, aussi appelée somme orthogonale de deux fonctions de croyance m_1 et m_2 est notée de la manière suivante :

$$m_{\oplus} = m_1 \oplus m_2 \quad (2.17)$$

La règle de Dempster redistribue cette masse de conflits de manière uniforme sur les autres éléments focaux comme suit :

$$m_{\oplus}(A) = \frac{1}{1-K} \sum_{B \cap C = A} m_1(B)m_2(C) \quad \forall A \subseteq \Theta, A \neq \emptyset \quad (2.18)$$

K est défini par :

$$K = \sum_{B \cap C = \emptyset} m_1(B)m_2(C) \quad (2.19)$$

Nous appelons degré de conflit (ou simplement conflit) entre les deux fonctions de masse m_1 et m_2 noté K , ou K reflète la masse de croyance conflictuelle existante entre les deux masses à combiner. Cette masse varie dans l'intervalle $[0,1]$ selon les fonctions m_1 et m_2 . Lorsque K est nul, les sources sont en parfait accord. Au contraire, lorsque cette masse est égale à 1, les sources sont en conflit total et les informations ne peuvent pas être fusionnées.

Nous pouvons généraliser la combinaison de Dempster à J fonctions de croyance en notant $m_{\oplus} = \oplus_{j=1}^J m_j$. la fonction m_{\oplus} est alors définie de la manière suivante [6]:

$$m_{\oplus}(A) = \frac{1}{1-K} \sum_{A_1 \cap \dots \cap A_J = A} \prod_{j=1}^J (m_j(A_j)) \quad \forall A \subseteq \Theta, A \neq \emptyset \quad (2.20)$$

$$K = \sum_{A_1 \cap \dots \cap A_J = \emptyset} \left(\prod_{j=1}^J m_j(A_j) \right) \quad (2.21)$$

La règle de combinaison de Dempster est commutative et associative. Par conséquent, l'ordre de combinaison des informations ne doit pas influencer sur le résultat lors de l'application de la règle de Dempster.

Enfin, la règle de combinaison de Dempster a fait l'objet de nombreuses critiques. La plupart de ces critiques sont liées à la normalisation. Smets [18] propose même l'abandon de cette normalisation.

2.4. Règles de décision

Une fois la masse résultante m ainsi obtenue, la décision peut alors être prise. Différentes règles de décision ont été définies, les plus courantes étant la règle du maximum de plausibilité et la règle du maximum de crédibilité [20]. À partir des fonctions de masse, Smets définit une fonction de probabilité appelée probabilité pianistique [18]. De manière générale, on définit la fonction de décision δ pour une forme entrante X à classer par :

$$\delta(X) = H_n \quad \text{ou} \quad H_n = \text{Arg} [\max \gamma(H_i)], H_i \in \Theta \quad (2.22)$$

γ est la fonction de crédibilité (*Bel*), ou de plausibilité (*pel*) ou de probabilité pianistique.

2.5. Modélisation des BF

Dans le cadre de la théorie de l'évidence pour l'association de données, il n'existe pas de méthodes génériques pour l'obtention des BF. Dans la plupart des cas, la modélisation utilisée dépend de l'application envisagée [21]. Dans notre travail, la méthode adoptée pour obtenir les fonctions de masses est influencé par l'algorithme pour résoudre le problème d'association de données pour la poursuite des véhicules [22], nous nous sommes intéressés aux deux approches :

- Approche fondée sur le calcul de la distance [23],
- Approche fondée sur le calcul de la vraisemblance [24,25].

Soit $\Omega = \{P_1, P_2, \dots, P_I\}$ et $\Theta = \{A_1, A_2, \dots, A_J\}$ respectivement l'ensemble de I cibles existantes et de J mesures reçues. Pour chaque cible et chaque mesure, nous définissons le cadre de discernement Ω_{ij} par :

$$\Omega_{ij} = \{P_i R A_j, \overline{P_i R A_j}\} \quad (2.23)$$

et l'ensemble $2^{\Omega_{ij}} = \{\emptyset, P_i R A_j, \overline{P_i R A_j}, \Theta\}$ (2.24)

$$\text{où } \begin{cases} P_i R A_j = \{(P_i, A_j)\} & : \text{association} \\ \overline{P_i R A_j} = \{(P_i, A_1), \dots, (P_i, A_{j-1}), (P_i, A_{j+1}), \dots, (P_i, A_J)\} & : \text{non association} \\ \Theta = \{(P_i, A_1), (P_i, A_2), \dots, (P_i, A_J)\} & : \text{ignorance} \end{cases} \quad (2.25)$$

Nous définissons la fonction de masse définissant la probabilité d'association de la cible i à la mesure j :

$$m_{ij} : 2^{\Omega_{ij}} \rightarrow [0,1] \quad (2.26)$$

Nous supposons que les sources d'informations (qui sont les mesures) sont parfaitement fiables, et l'ignorance totale sur l'association est nulle, donc :

$$m_{ij}(\emptyset) = 0 \quad \text{et} \quad m_{ij}(\Theta) = 0 \quad (2.27)$$

Alors : $m_{ij}(P_i R A_j) = 1 - m_{ij}(\overline{P_i R A_j})$ (2.28)

Nous notons : $m_{ij} = m_{ij}(P_i R A_j) \quad \text{et} \quad \overline{m_{ij}} = m_{ij}(\overline{P_i R A_j})$ (2.29)

Nous construisons le tableau (2.1).

Tableau 2.1 : Génération des masses

	A_1	$\overline{A_1}$...	A_j	$\overline{A_j}$...	A_j	$\overline{A_j}$
P_1	m_{11}	$\overline{m_{11}}$...	m_{1j}	$\overline{m_{1j}}$...	m_{1j}	$\overline{m_{1j}}$
\vdots
P_i	m_{i1}	$\overline{m_{i1}}$...	m_{ij}	$\overline{m_{ij}}$...	m_{iJ}	$\overline{m_{iJ}}$
\vdots
P_I	m_{I1}	$\overline{m_{I1}}$...	m_{Ij}	$\overline{m_{Ij}}$...	m_{IJ}	$\overline{m_{IJ}}$

Nous appliquons la règle de combinaison conjonctive (équation (2.15)) pour chaque cible et chaque mesure, nous aurons la table de croyance (tableau (2.2)).

Tableau 2.2 : Tableau de croyance

	A_1	A_2	...	A_j	\emptyset
P_1	$m_{\cap 11}$	$m_{\cap 12}$...	$m_{\cap 1j}$	$m_{\cap 1\emptyset}$
P_2	$m_{\cap 21}$	$m_{\cap 22}$...	$m_{\cap 2j}$	$m_{\cap 2\emptyset}$
...
P_I	$m_{\cap I1}$	$m_{\cap I2}$...	$m_{\cap Ij}$	$m_{\cap I\emptyset}$

$$\text{Où } m_{\cap i\emptyset} = 1 - \sum_{j=1}^J m_{\cap ij} = K_i \quad (2.30)$$

K_i : représente le conflit sur l'association de la $i^{\text{ème}}$ cible avec les mesures reçues.

Par la suite, nous faisons la normalisation par rapport au K_i (équation (2.18)), et nous aurons donc les masses de croyances normalisées. Comme règle de décision, nous choisissons pour chaque cible l'observation ayant le maximum de crédibilité pour la mise à jour de l'état de la cible.

La principale difficulté de la théorie de Dempster-Shafer réside dans la modélisation des fonctions de croyance qui dépend de l'application envisagée.

2.6. Simulation numérique

Dans ce chapitre, on va présenter les performances de la Théorie de Dempster-Shafer dans la poursuite multi-cibles dans différents cas et essentiellement la probabilité de la bonne association de données, celle ci est connue par la fusion des données incertaines (combinaison de Dempster) cette propriété de la méthode sera utilisé pour associer à chaque cible la mesure correspondante comme l'indique la figure (2.4) où Θ représente l'ensemble des cibles et Ω représente l'ensemble des mesures.

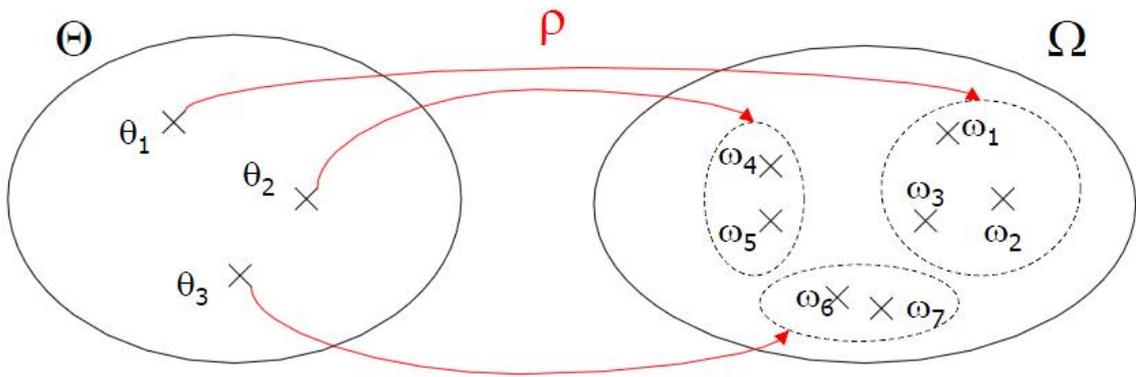


Figure 2.4 : Association des mesures aux cibles correspondantes

- **Modèles de mouvements**

Dans notre travail on va utiliser un modèle de mouvement **rectiligne à vitesse constante** pour différent cas (soit N le nombre d'échantillon):

- 3 cibles parallèles de séparation 50 m, 100 m et 150 m
- 3 cibles qui se croisent à $N/4$, $N/2$, $3N/4$

Soit à l'instant k le vecteur (modèle d'état) suivant :

$$\underline{X}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T \quad (2.31)$$

Ce dernier est composé des paramètres de la cible (abscisse, vitesse sur l'abscisse, ordonnée et vitesse sur l'ordonnée) qui sont inconnus et qui doivent être estimés.

Dans le modèle de mouvement **rectiligne à vitesse constante**, la fonction $f_1(\underline{X}_k)$ et la matrice G_1 sont données par [26] :

$$f_1(\underline{X}_k) = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \underline{X}_k \quad \text{Et} \quad G_1 = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix} \quad (2.32)$$

T représente la période d'échantillonnage (période d'un tour radar).

- **Modèle de travail**

La méthode adoptée pour notre travail est représentée dans la figure (2.5) En premier lieu, on va modéliser les informations par les fonctions de masse élémentaires puis on va combiner les masses résultantes avec la combinaison de Dempster, par la suite on va prendre le maximum de crédibilités comme règle de décision.

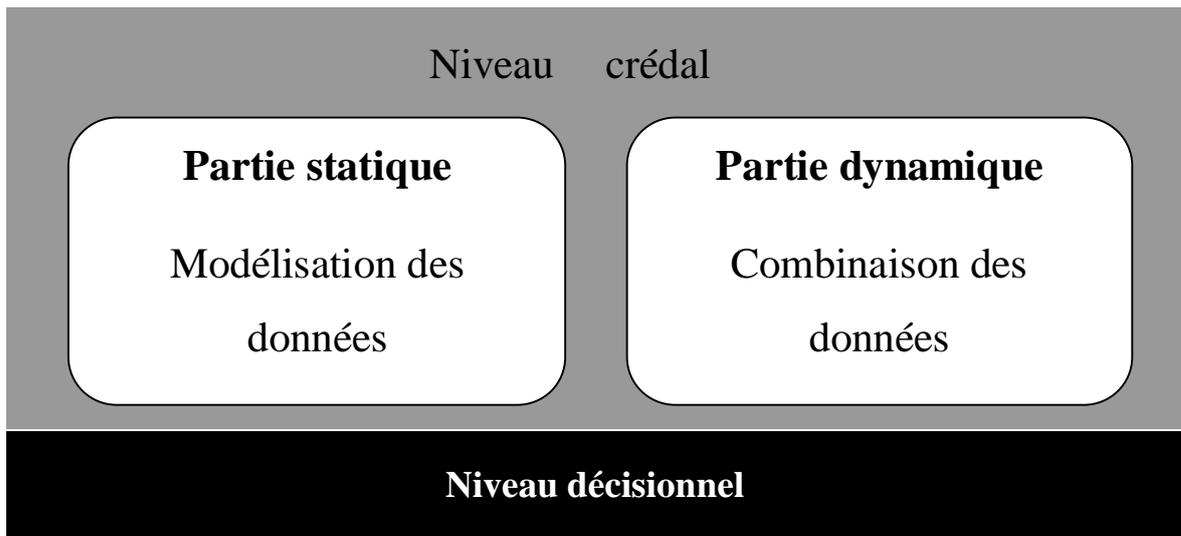


Figure 2.5 : Etapes d'association de données

Partie statique :

Dans notre travail le modèle que nous proposons pour l'association de données dans le cadre de la poursuite multi-cibles a été inspiré du modèle d'Appriou [27].

Pour la construction de notre modèle, nous passons par les étapes suivantes :

a. Notre cadre de discernement est composé de deux hypothèses, $\Omega_{ij} = \{H_1, H_2\}$ avec :

- H_1 : la cible i est associée à l'observation j
- H_2 : la cible i n'est pas associée à l'observation j , donc $H_2 = \overline{H_1}$

b. Nous définissons l'ensemble 2^N ($N=2$) parti de Ω_{ij} par :

$$2^{\Omega_{ij}} = \{\{H_1\}, \{H_2\}, \{H_1, H_2\}, \emptyset\}$$

c. Nous accordons une masse de croyance à chaque élément $A \in 2^{\Omega_{ij}}$:

- $m_{ij}(\{H_1\}) = m(i, j)$: masse d'association de la cible i à l'observation j ,
- $m_{ij}(\{H_2\}) = 1 - m(i, j)$: masse d'ignorance d'association de la cible i aux observations j' ($j' \neq j$),
- $m_{ij}(\{H_1, H_2\}) = 0$: masse d'ignorance d'association de la cible i à l'observation j .
- $m_{ij}(\emptyset) = 0$: masse d'association et de la non-association de la cible i à l'observation j .

d. Nos sources d'information sont les observations (la dimension de l'observation égale à 2).

$$\text{Soit : } G(i, j) = \frac{1}{2\pi\sqrt{|S_i|}} \cdot \exp\left(-\frac{1}{2} \cdot (y_j - yp_i)^T \cdot (S_i)^{-1} \cdot (y_j - yp_i)\right) \quad (2.33)$$

Nous définissons $m(i, j)$ par [28], [29] :

$$m_{norm}(i, j) = \frac{G(i, j)}{\max_j [G(i, j)]} \quad \rightarrow \quad m(i, j) = \frac{m_{norm}(i, j)}{\sum_j^{NbrMesures} [m_{norm}(i, j)]} \quad (2.34)$$

- $NbrMesures$: Nombre d'observations reçues à l'instant k
- y_j : $j^{\text{ème}}$ observation reçue
- yp_i : l'observation prédite de la cible i
- S_i : matrice de covariance d'innovation de la cible i

Le modèle devient :

$$\begin{cases} m_{ij}(\{H_1\}) = m(i, j) \\ m_{ij}(\{H_2\}) = 1 - m(i, j) \\ m_{ij}(\text{ign}) = 0 \\ m_{ij}(\emptyset) = 0 \end{cases} \quad (2.35)$$

où $\begin{cases} m(H_1) \text{ probabilité d'association de la cible } i \text{ à l'observation } j \\ m(H_2) \text{ probabilité de la non association de la cible } i \text{ à l'observation } j \\ m(\text{ign}) \text{ probabilité d'ignorance sur l'association de la cible } i \text{ à l'observation } j \end{cases}$

Partie dynamique :

Après l'étape de modélisation, nous appliquons la règle de combinaison de Dempster (équation (2.18)), et la décision sera faite par le maximum de crédibilité sur la masse après combinaison.

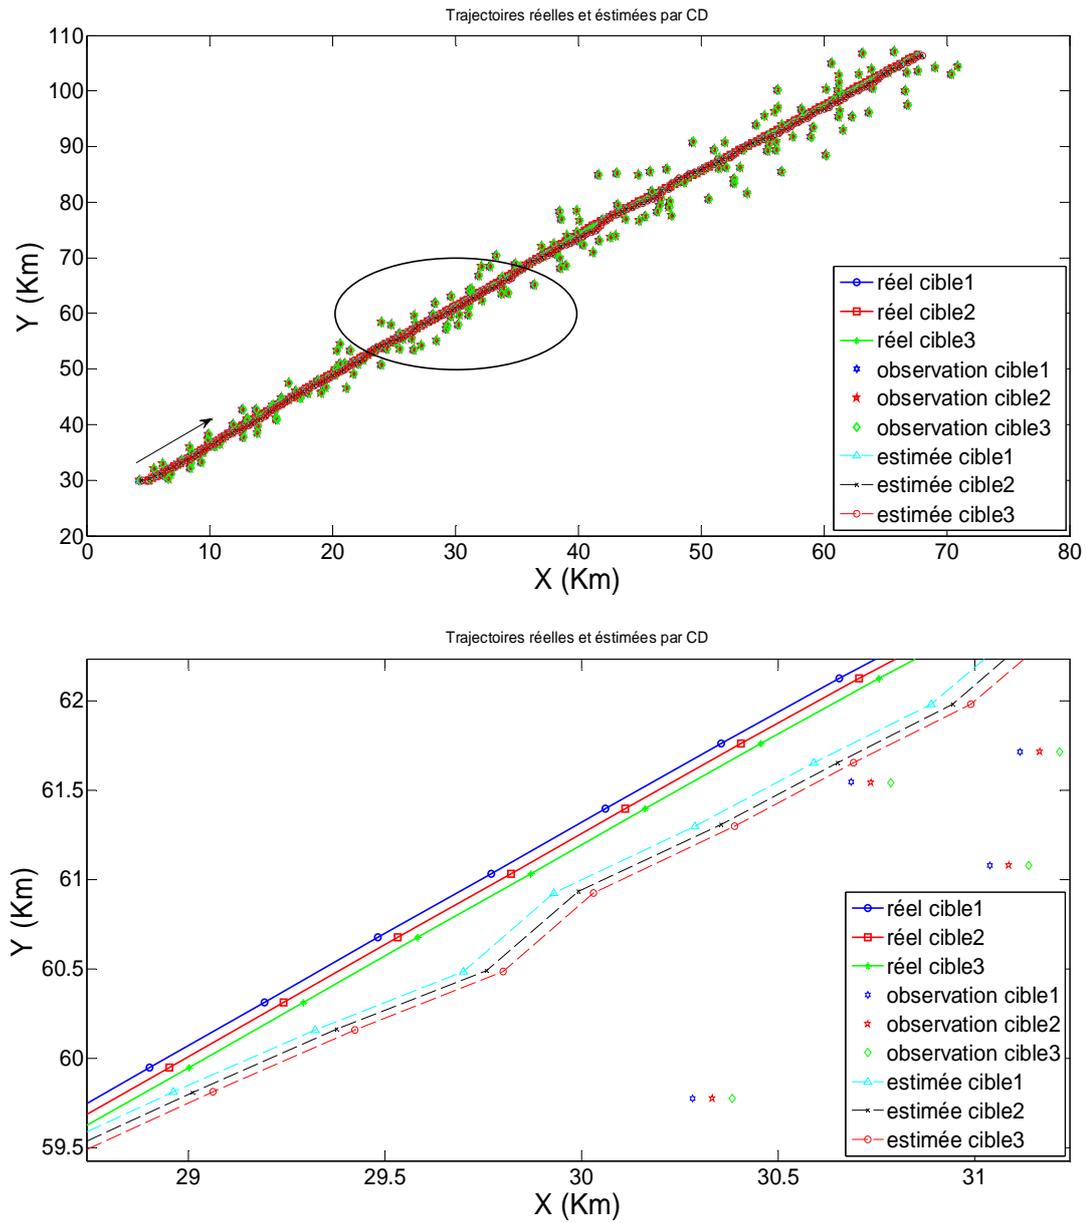


Figure 2.6 : Trajectoires réelles et estimées par DST des trois cibles parallèles

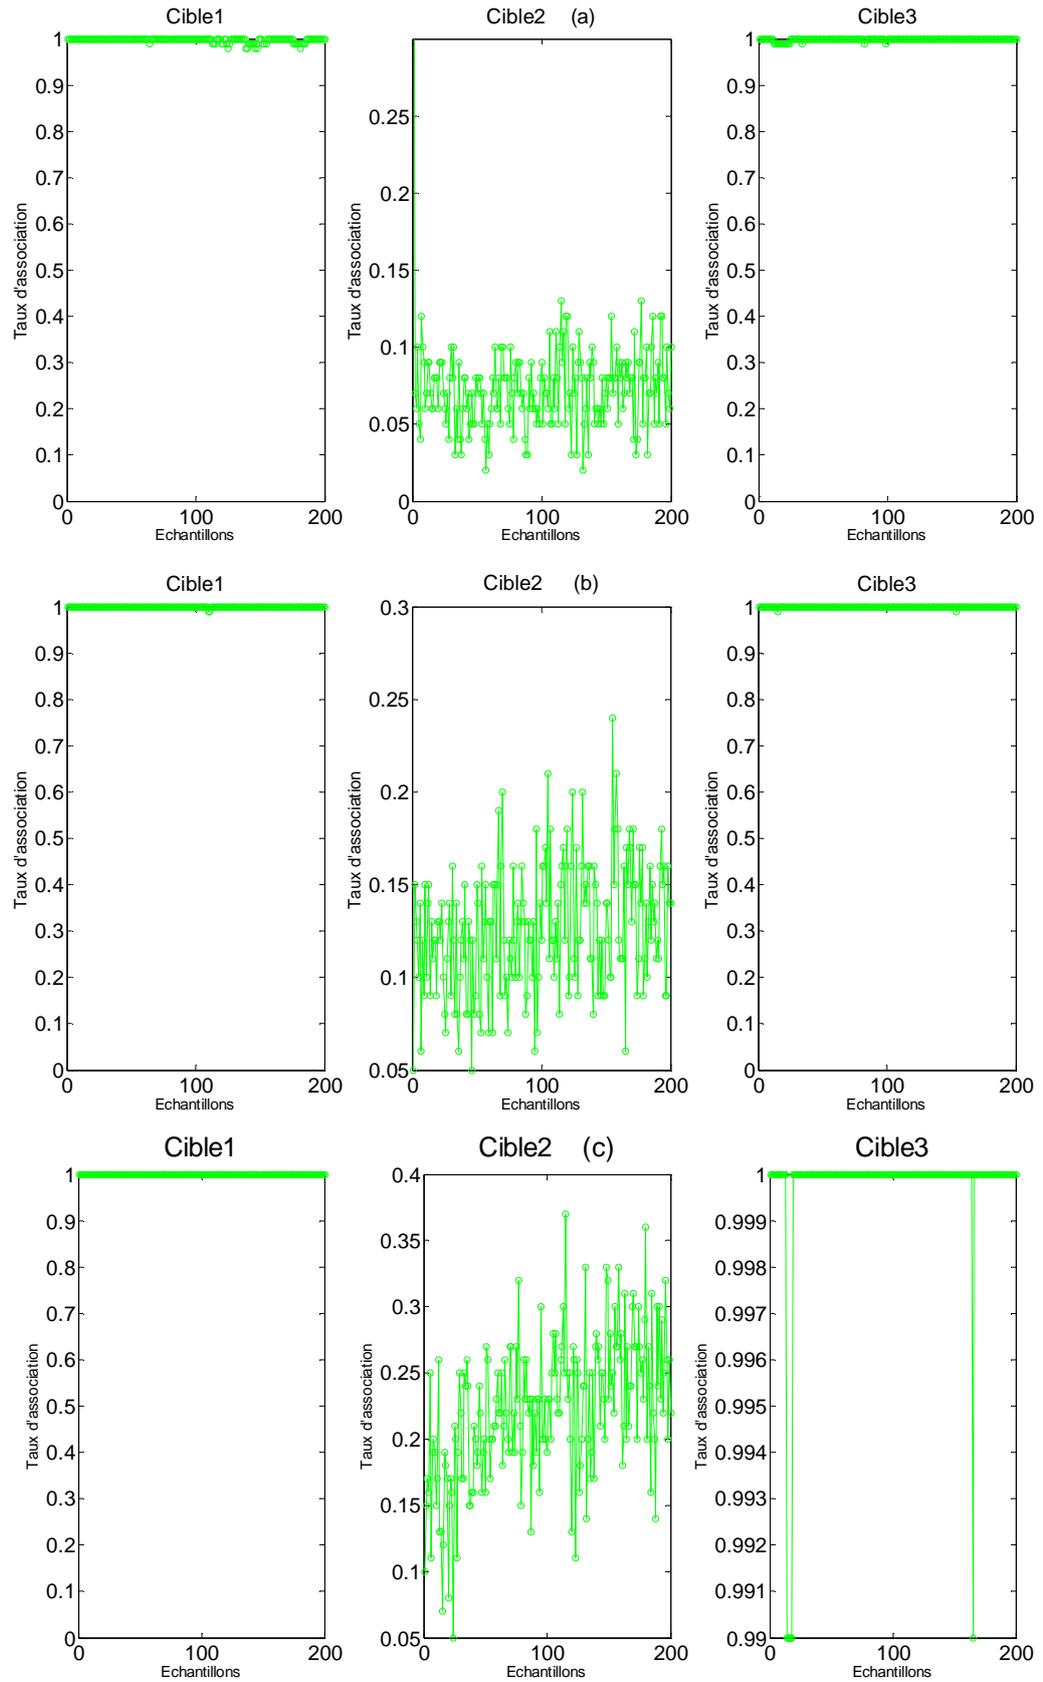


Figure 2.7 : Taux d'association des trois cibles parallèles
 (a) séparations entre les cibles 50m (b) séparations entre les cibles 100m (c) séparations entre les cibles 150m

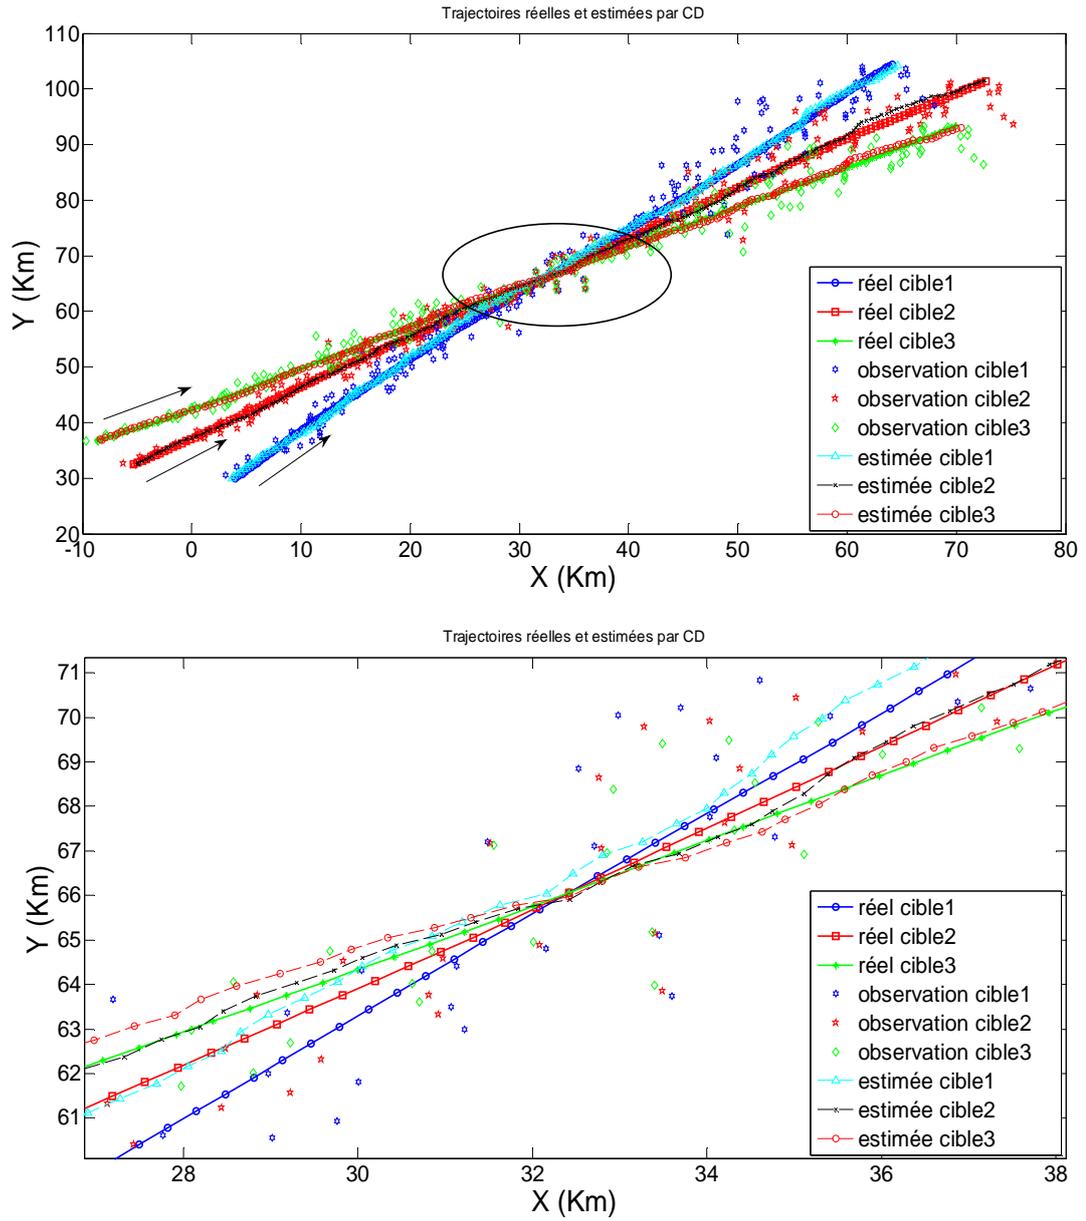


Figure 2.8 : Trajectoires réelles et estimées par DST des trois cibles qui se croisent

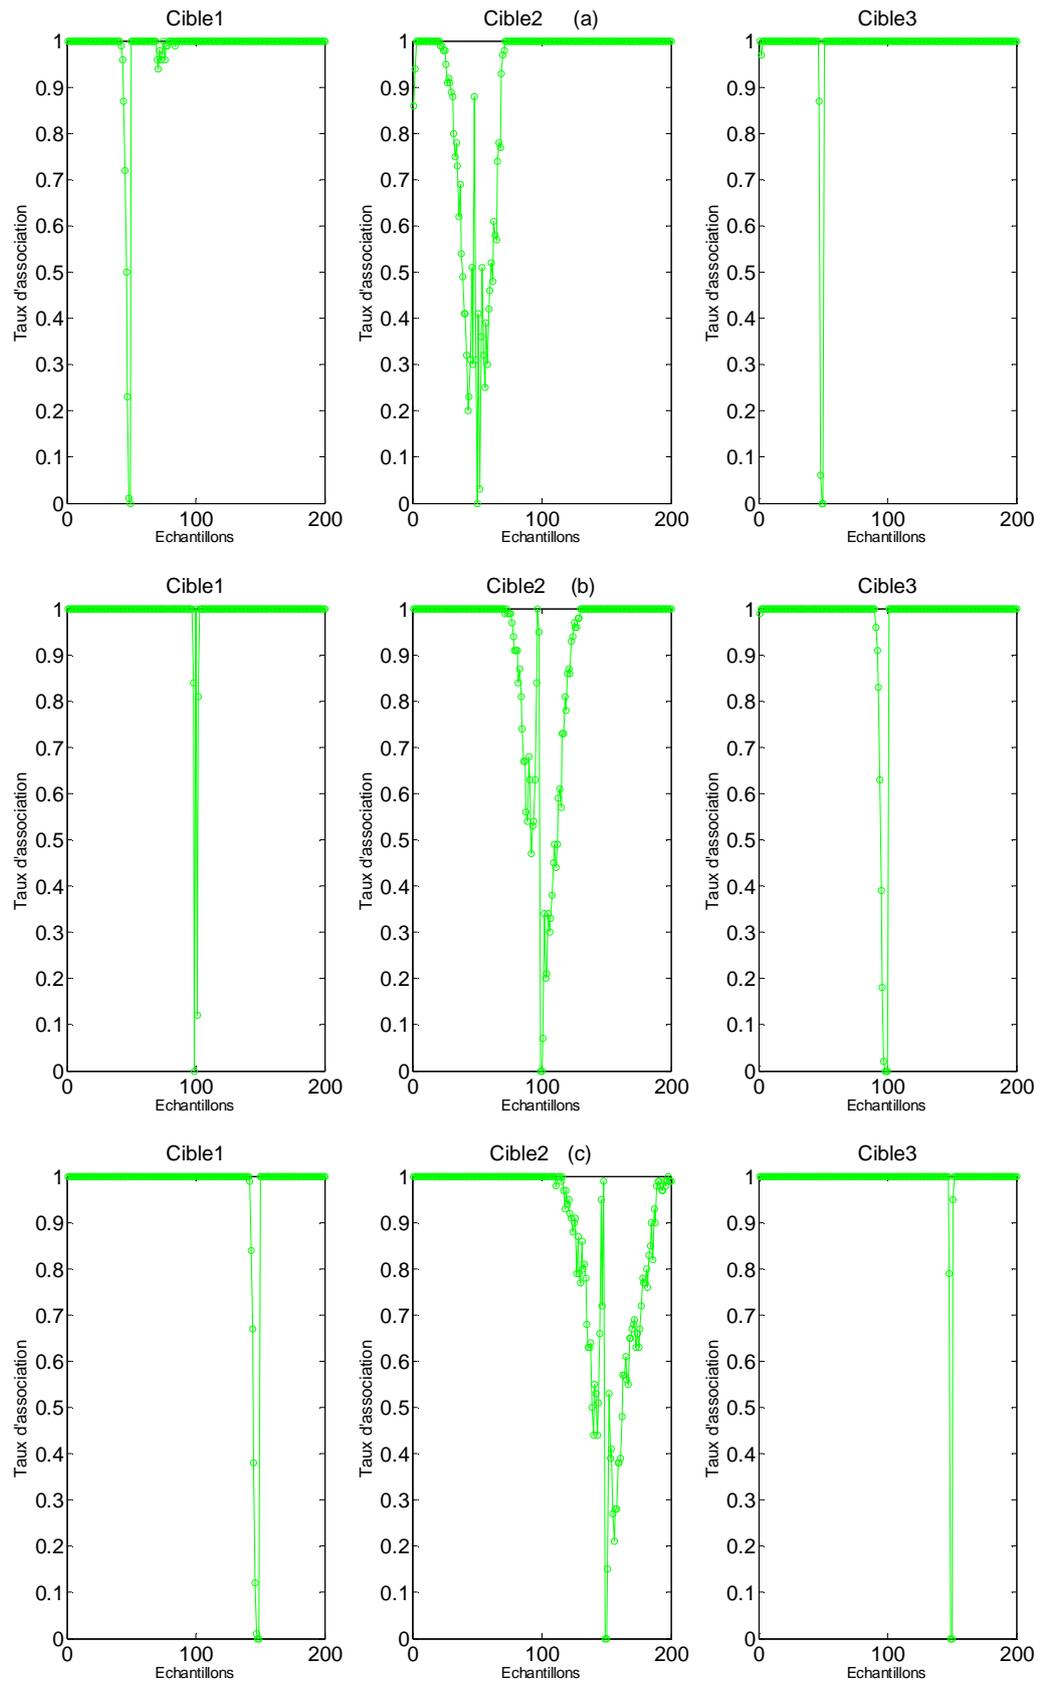


Figure 2.9 : Taux d'association des trois cibles qui se croisent

(a) Point d'intersection $N/4$ (b) point d'intersection $N/2$ (c) point d'intersection $3N/4$

Dans cette simulation nous avons étudié les performances de la poursuite multi-cibles obtenues par l'association de données par la théorie de "Dempster-Shafer". L'analyse de résultats précédents des deux scénarios à trois cibles parallèles et en croisement nous permet d'effectuer les remarques suivantes :

3 cibles parallèles

- Les trajectoires estimées par DST sont très proches des trajectoires réelles, la séparation entre les cibles est évidente. On voit que les trois cibles ne sont pas confondues et ne se croisent pas durant tout le trajet.
- La probabilité de la bonne association est très bonne sauf pour la cible du milieu, ceci est dû à la séparation entre les cibles. Si on augmente la séparation entre les cibles, la probabilité de la bonne association augmente.

3 cibles qui se croisent

- la trajectoire estimée par DST est similaire aux trajectoires réelles des trois cibles, la séparation entre les cibles est évidente et le point d'intersection des cibles est très proche du point d'intersection réel.
- La probabilité de la bonne association est correcte, elle subit cependant une descente nulle aux points d'intersection ($N/4$, $N/2$, $3N/4$) puis elle reprend sa valeur initial sauf pour la cible 2, ceci est dû à la situation de grande ignorance.

2.7. Conclusion

Dans ce chapitre, nous avons présenté la théorie de “Dempster-Shafer“, ou la théorie de l’évidence, à partir des mathématiques probabilistes, présente un cadre formel de raisonnement dans l’incertain et un modèle qui permet de modéliser d’une manière plus adapté les informations incertaines et imprécises. En effet, à travers les fonctions de masses qui sont des outils de mesure de la probabilité subjective, on peut évaluer le degré de vérité d’une affirmation. Avec l’introduction des masses d’évidence, la règle de combinaison de Dempster permet de traiter l’information au point d’aboutir à sa fiabilité. Ce qui aide grandement dans la prise de décision basée sur le maximum de crédibilité.

La modélisation des données détermine les bonnes performances d’association, dans ce mémoire nous travaillons avec un modèle de modélisation pour l’obtention des fonctions d’évidence pour l’association de données. Ce modèle est inspiré des travaux d’Appirou [28].

Dans ce travail, nous avons présenté les performances de la poursuite multi-cibles et de l’association de données obtenues par notre méthode, les résultats obtenus par la simulation ont démontré la bonne performance de la théorie de “Dempster-Shafer“.

Pour valider nos résultats, dans le chapitre suivant nous allons comparer sur plusieurs critères la méthode d’association de données par la théorie de l’évidence avec les méthodes d’association de données les plus connues pour la poursuite multi-cibles avec la présence de clutter (fouillis).

CHAPITRE 3

ETUDES DES PERFORMANCES DE LA POURSUITE DE CIBLES NON MANOEUVRANTES

3.1. Introduction

La poursuite de cibles non manoeuvrantes consiste principalement en deux étapes ou opérations : l'association de données et le filtrage. La principale difficulté de la poursuite multi-cibles vient du fait que nous ne pouvons pas associer à priori une observation à une cible présente dans le champ de vision du capteur. Cette difficulté s'accroît si nous considérons que le capteur peut générer des fausses alarmes, c'est-à-dire des observations ne correspondant à aucune cible existante, ou si nous ne connaissons pas le nombre de cibles présent dans le volume d'observation et si ce nombre peut évoluer au cours du temps.

Dans ce chapitre nous allons voir les performances de la poursuite des multi-cibles non manoeuvrantes par différentes méthodes d'association avec le filtre de Kalman étendu pour la poursuite ; Dans ce chapitre, nous commençons par présenter le modèle d'état de cible considéré dans ce travail puis nous abordons le filtre de Kalman étendu que nous utilisons pour la prédiction et l'estimation des paramètres de cibles. Par la suite, nous donnons les deux méthodes d'association de données la méthode de plus proche voisin (NN) et le filtre d'association de données par probabilités conjointes (JPDA) qu'on va utiliser pour les comparer avec la méthode d'association de données par la combinaison de Dempster (CD) et un aperçu sur le clutter de mer sera exposé ensuite. Nous présentons les résultats de simulation numérique pour la poursuite multi-cibles pour différent scénario, avec et sans la présence de clutter afin de voir les performances de la poursuite, En fin nous terminons ce chapitre par une conclusion.

3.2. Modélisation d'état

Dans ce paragraphe nous allons présenter le modèle d'état de cible qui sera utilisé dans ce chapitre. On va travailler avec des cibles non manoeuvrantes [30], par exemple des avions de l'aviation civile volant suivant une trajectoire rectiligne sans changement brusque de mouvements. En effet, soit à l'instant k le vecteur suivant :

$$\underline{X}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T \quad (3.1)$$

Dans le cadre de la poursuite multi-cible, chaque cible individuelle peut être vue comme un système dynamique indépendant, dont l'évolution temporelle peut être modélisée sous la forme d'une équation. Au vu de la modélisation de l'état d'une cible (équation (3.1)) et du format des mesures, nous nous limitons au cas linéaire puisque l'état x_k d'une cible à l'itération k est caractérisé par les équations de mouvement (3.2) et d'observation (3.3) par une mesure \underline{Z}_k suivante [31] :

$$\begin{cases} \underline{X}_{k+1} = f(\underline{X}_k) + G w_k \\ \underline{Z}_k = h(\underline{X}_k) + v_k \end{cases} \quad k \geq 0 \quad (3.2)$$

$$h(\underline{X}_k) = \begin{pmatrix} \sqrt{(x_k - x_c)^2 + (y_k - y_c)^2} \\ \arctan((y_k - y_c)/(x_k - x_c)) \end{pmatrix} \quad (3.3)$$

(x_c, y_c) est la position du capteur

Où f est la matrice de transition d'état de la cible caractérisant l'évolution du système et h est la matrice de transition de l'espace d'état vers l'espace des mesures (équation (3.3)). Gw_k est un vecteur de bruit d'état dont les propriétés statistiques (moyenne, covariance) caractérisent les limites du modèle utilisé (exactitude de la matrice de transition, finesse du modèle d'état). Par exemple, le système modélise un mouvement à vitesse constante. Si l'avion accélère alors un bruit de mesure apparaît, car le modèle n'est pas adapté à ce comportement. Nous décrivons maintenant ces différentes grandeurs avec plus de détails. Si une cible j est définie par sa position et sa vitesse telle que :

$$x_k = \begin{bmatrix} x_k \\ \dot{x}_k \\ y_k \\ \dot{y}_k \end{bmatrix} \quad (3.4)$$

Cette cible évolue selon une trajectoire rectiligne et avec une vitesse constante, la matrice de transition d'état f est telle que :

$$f = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.5)$$

Elle correspond au système d'évolution séquentiel suivant :

$$\left\{ \begin{array}{l} x_{k+1} = x_k + T\dot{x}_k \\ \dot{x}_{k+1} = \dot{x}_k \\ y_{k+1} = y_k + T\dot{y}_k \\ \dot{y}_{k+1} = \dot{y}_k \end{array} \right\} \quad (3.6)$$

Où T est la période d'échantillonnage du capteur. La matrice f traduit donc bien une relation linéaire entre x_{k+1} et x_k .

Le bruit w_k est modélisé par un bruit blanc gaussien centré sur 0, de covariance connue Q_k qui modélise les incertitudes sur le modèle utilisé tel que :

$$E\left[[G.w_k].[G.w_k]^T\right] = G.Q_m.G^T \quad (3.7)$$

Et G permet de décrire l'incertitude comme étant l'erreur de modélisation engendrée par l'approximation effectuée sur l'accélération comme définie [32] :

$$G = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix} \quad (3.8)$$

Finalement, la covariance de bruit s'écrit :

$$Q_k = E\left[G.G^T\right] = \begin{pmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{pmatrix} \otimes \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad (3.9)$$

Avec σ_x et σ_y les écarts-types respectifs associés à l'incertitude sur la composante accélération dans les deux directions X et Y du référentiel local. Ils sont considérés égaux et représentés finalement par q le bruit de modèle, autrement dit une mesure de la confiance accordée au modèle.

3.3. Filtre de Kalman

Le filtrage consiste à estimer de façon récursive un état caché au vu d'observations. Le domaine d'application principal est la localisation, la navigation et la poursuite de mobiles. Le filtre de poursuite remplit les deux fonctions qui sont l'estimation de l'état de la cible, et la prédiction de son état futur sur la base de la dynamique de son mouvement. Plusieurs filtres ont été développés, on cite comme exemple le filtre de Kalman qui est le plus utilisé dans la poursuite radar.

3.3.1. Les applications du filtre

Le filtre de Kalman permet de donner un estimé de l'état de système à partir d'une information à priori sur l'évolution de cet état (modèle) et de mesures réelles, il sera utilisé pour :

- Estimer les conditions initiales inconnues (balistique)
- Prédire des trajectoires de mobiles (trajectographie)
- Localiser un engin (navigation, radar...)
- Implanter des lois de commande fondées sur un estimateur de l'état et un retour d'état (Commande linéaire quadratique gaussienne)

3.3.2. Filtre de Kalman discret

Le filtre de Kalman pose le problème général de l'essai d'estimation de l'état $x \in \mathbf{R}^n$ d'un processus commandé par temps discret qui est régi par l'équation de différence stochastique linéaire :

$$x_k = Fx_{k-1} + Gu_{k-1} + w_{k-1} \quad (3.10)$$

Avec la mesure $z \in \mathbf{R}^m$ qui est :

$$z_k = H x_k + v_k \quad (3.11)$$

Les variables aléatoires w_k et v_k représentent le bruit d'état et de mesure (respectivement). On admet qu'ils sont indépendants l'un de l'autre, blancs, et avec des probabilités de distributions normales :

$$p(w) \approx N(0, Q) \quad (3.12)$$

$$p(v) \approx N(0, R) \quad (3.13)$$

Dans la pratique, la covariance de bruit Q et les matrices de covariance de bruit de système. R est la matrice de covariance de bruit de mesure.

La matrice $F(k)$ de dimension $(n \times n)$ dans l'équation (3.10) relie l'état à l'étape précédente de temps $k-1$ à l'état à l'étape courante k . notons que dans la pratique $F(k)$ pourrait changer avec chaque période de temps.

La matrice $G(k)$ relie l'entrée de commande facultative $u \in \mathbf{R}^1$ à l'état x . La matrice $H(k)$ de dimension $(m \times n)$ dans l'équation de mesure (3.11) relie l'état à la mesure $z(k)$. Dans la pratique H pourrait changer chaque fois avec l'état ou la mesure.

En dérivant les équations pour le filtre de Kalman, nous trouvons une équation qui calcul a posteriori une estimation d'état $\hat{\underline{X}}_k$ comme combinaison linéaire d'une estimation à priori $\hat{\underline{X}}_{k/k-1}$ et une différence pondérée entre une mesure réelle \underline{Z}_k et la prédiction de la mesure $H(\hat{\underline{X}}_{k/k-1})$ comme montrée dans l'équation (3.14) [33].

$$\hat{\underline{X}}_k = \hat{\underline{X}}_{k/k-1} + K_k \left[\underline{Z}_k - H_k(\hat{\underline{X}}_{k/k-1}) \right] \quad (3.14)$$

$\hat{\underline{X}}_{k/k-1}$: grande incertitude sur la mesure (Prédiction favorisée).

$\underline{Z}_k - H_k(\hat{\underline{X}}_{k/k-1})$: grande incertitude sur le modèle (innovation favorisée).

La figure (3.1) offre une image complète du fonctionnement du filtre.

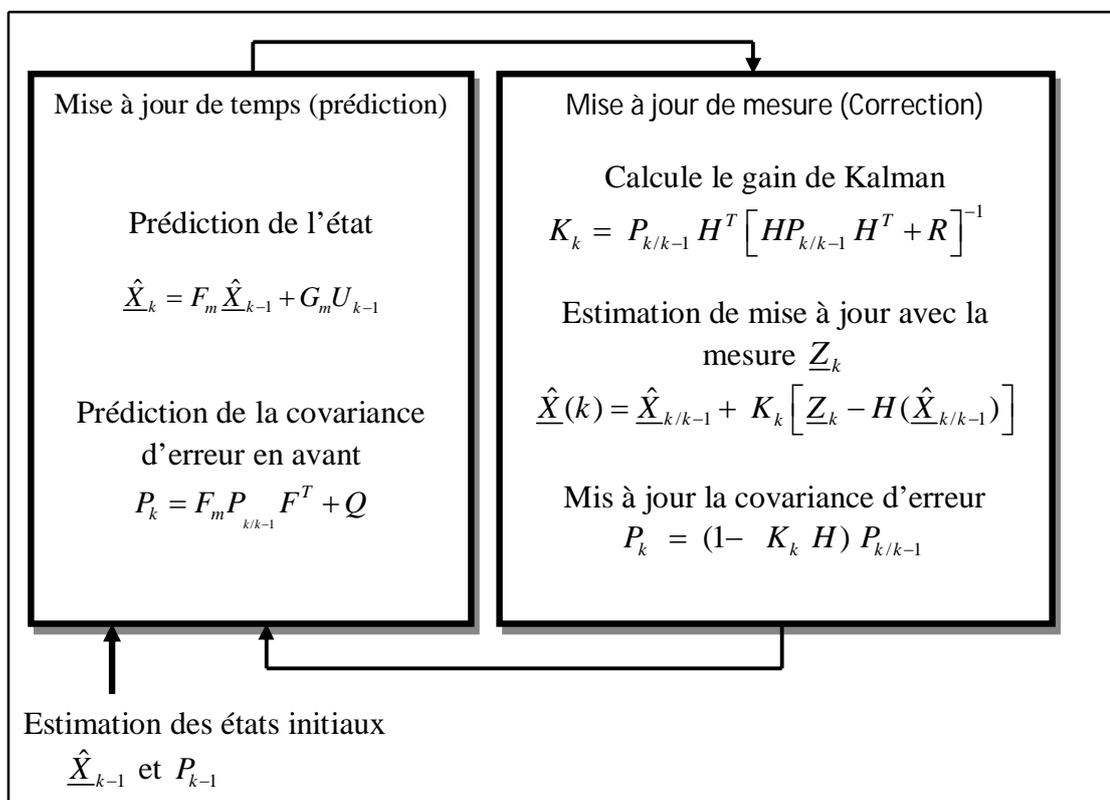


Figure 3.1 : Schéma de l'algorithme du filtre de Kalman

3.3.3. Filtre de Kalman étendu

Comme décrit précédemment, le filtre de Kalman s'intéresse au problème général de l'estimation de l'état $x \in \mathbf{R}^n$ d'un processus discret régi par une équation différentielle linéaire stochastique.

Mais que se passe-t-il si le processus à estimer et (ou) la relation entre la mesure et le processus sont non linéaires ? Certaines applications, les plus intéressantes et les plus réussies du filtrage de Kalman ont été dans telles situations. Un filtre de Kalman qui linéarise autour de la moyenne et de la covariance est désigné sous le nom de filtre de Kalman étendu (ou EKF pour Extended Kalman Filter) [33].

En utilisant un développement en série de Taylor, nous pouvons linéariser l'estimation autour de l'estimée courante en utilisant les dérivées partielles des fonctions du processus et de mesure pour calculer des estimations même face à des équations différentielles non linéaires.

Supposons que notre processus a un vecteur d'état régi par l'équation différentielle stochastique non linéaire suivante :

$$x_k = f(x_{k-1}, u_{k-1}, w_{k-1}) \quad (3.15)$$

Avec la mesure $z \in \mathbf{R}^m$ qui est :

$$z_k = h(x_k, v_k) \quad (3.16)$$

Où les variables aléatoires w_k et v_k représentent les bruits d'état et de mesure comme dans l'équation (3.12) et (3.13).

La fonction f non linéaire dans l'équation différentielle (3.15) relie l'état à l'étape $k-1$ à l'état à l'étape courante k . Elle inclut les paramètres de commande u_{k-1} et le bruit du processus w_k de moyenne nulle. La fonction non linéaire h dans l'équation de mesure (3.16) relie l'état x_k à la mesure z_k . Dans la pratique, on ne connaît pas les valeurs du bruit w_k et v_k à chaque instant. Cependant, on peut approximer le vecteur d'état et de mesure sans elles en écrivant :

$$\hat{X}_k = f(\hat{X}_{k-1}, u_{k-1}, 0) \quad (3.17)$$

$$\hat{z}_k = h(\hat{X}_k, 0) \quad (3.18)$$

Où \hat{X}_k est une certaine estimation à priori de l'état.

Il est important de noter qu'une faille fondamentale de l'EKF est que les distributions (ou les densités dans le cas continu) des diverses variables aléatoires ne sont plus normales après avoir subi les transformations non linéaires respectives. L'EKF est simplement un estimateur Ad-Hoc d'état qui approche seulement l'optimalisé de la règle de Bayes par la linéarisation.

Pour estimer le processus non linéaire, nous commençons par écrire des nouvelles équations qui linéarisent les estimées autour des équations (3.17) et (3.18) :

$$X_k = \mathfrak{X}_k + A(X_{k-1} - \hat{X}_{k-1}) + Ww_{k-1} \quad (3.19)$$

$$Z_k = \mathfrak{Z}_k + H(X_k - \mathfrak{X}_k) + Vv_k \quad (3.20)$$

- X_k et Z_k sont les vecteurs réels d'état et de mesure
- \mathfrak{X}_k et \mathfrak{Z}_k sont les vecteurs approchés d'état et de mesure
- \hat{X}_k est une estimée à postériori de l'état à l'instant k
- w_k et v_k représentent les bruits d'état et de mesure
- A est la matrice jacobienne des dérivées partielles de f en fonction de x , soit :

$$A_{[i,j]} = \frac{df_{[i]}}{dx_{[j]}}(\hat{X}_{k-1}, U_{k-1}, 0) \quad (3.21)$$

- W est la matrice jacobienne des dérivées partielles de f en fonction de w :

$$W_{[i,j]} = \frac{df_{[i]}}{dw_{[j]}}(\hat{X}_{k-1}, U_{k-1}, 0) \quad (3.22)$$

- H est la matrice jacobienne des dérivées partielles de h en fonction de x :

$$H_{[i,j]} = \frac{dh_{[i]}}{dx_{[j]}}(\mathfrak{X}_k, 0) \quad (3.23)$$

- V est la matrice jacobienne des dérivées partielles de h en fonction de v :

$$V_{[i,j]} = \frac{dh_{[i]}}{dv_{[j]}}(\mathfrak{X}_k, 0) \quad (3.24)$$

La linéarisation du modèle d'état au premier ordre est donnée d'une manière générale par [34]:

$$\begin{cases} \underline{X}_{k+1} = f_m(\hat{\underline{X}}_{k/k}) + F_m(\hat{\underline{X}}_{k/k}) [\underline{X}_k - \hat{\underline{X}}_{k/k}] + G_m w_k \\ \underline{Z}_k = h(\hat{\underline{X}}_{k/k-1}) + H(\hat{\underline{X}}_{k/k-1}) [\underline{X}_k - \hat{\underline{X}}_{k/k-1}] + v_k \end{cases} \quad k \geq 0 \quad (3.25)$$

L'ensemble complet d'équations EKF est donné ci-dessous dans les équations (3.26) à (3.30) [33]:

$$\hat{\underline{X}}_{k/k-1} = f_m(\hat{\underline{X}}_{k-1}) \quad (3.26)$$

$$P_{k/k-1} = F_m(\hat{\underline{X}}_{k-1}) P_{k-1} F_m^T(\hat{\underline{X}}_{k-1}) + G_m Q G_m^T \quad (3.27)$$

$$P_k = P_{k/k-1} - K_k H(\hat{\underline{X}}_{k/k-1}) P_{k/k-1} \quad (3.28)$$

$$\hat{\underline{X}}_k = \hat{\underline{X}}_{k/k-1} + K_k [\underline{Z}_k - h(\hat{\underline{X}}_{k/k-1})] \quad (3.29)$$

$$K_k = P_{k/k-1} H^T(\hat{\underline{X}}_{k/k-1}) [H(\hat{\underline{X}}_{k/k-1}) P_{k/k-1} H^T(\hat{\underline{X}}_{k/k-1}) + R]^{-1} \quad (3.30)$$

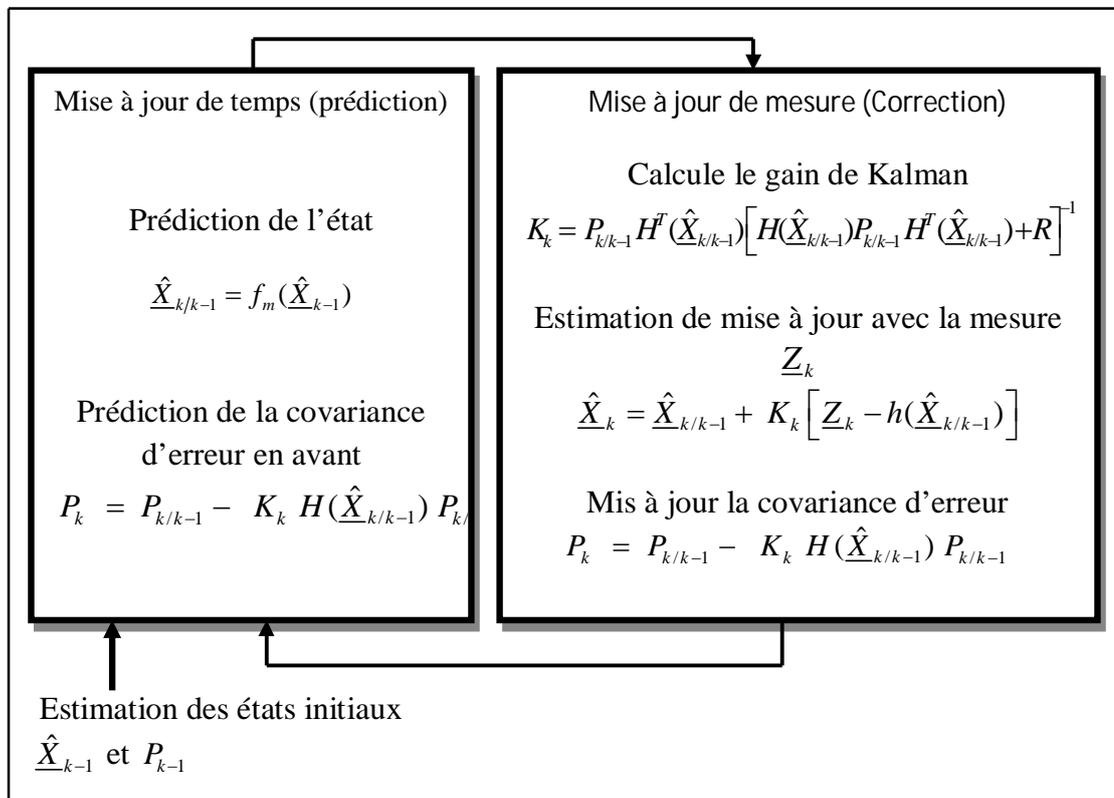


Figure 3.2 : Schéma de l'algorithme du filtre de Kalman étendu [34]

3.4. Autres méthodes d'association de données

Il existe fondamentalement deux modèles différents sur lesquels les algorithmes d'association de données peuvent être construits.

Le premier est déterministe, où il est considéré que le résultat de l'association est certain et dans ce cas, un test sur les hypothèses d'association est effectué pour sélectionner la plus probable en acceptant les hypothèses sujettes à des probabilités d'erreurs. Le résultat d'une association déterministe est un ensemble d'observations assignées aux différentes pistes existantes, qui seront utilisées directement dans l'algorithme de poursuite mis en place pour une éventuelle mise à jour des états estimés.

Le deuxième modèle est probabiliste, où les probabilités des différents événements (Ex. : la mesure « x » appartient à la cible « y ») pour chaque cible sont calculées, ainsi toutes les mesures appartenant à la région formée par les différentes fenêtres des pistes existantes, seront considérées avec des pondérations différentes pour la mise à jour d'une piste à la fois.

Dans ce travail, nous nous proposons de comparer à chaque fois les performances de poursuite et de classification de mouvement obtenues par la méthode d'association en utilisant DST avec les performances obtenues en utilisant les NN et le JPDA. C'est pourquoi nous allons dans ce paragraphe présenter brièvement le principe de ces deux méthodes.

3.4.1. Méthode du plus proche voisin NN

Cette méthode est plus connue sous la désignation anglo-saxonne de NN (Nearest Neighbour). Il existe différentes versions [35]. C'est une approche purement séquentielle : pour chaque nouvel ensemble d'observations, le but est de trouver l'association la plus probable entre une observation et une piste existante, ou entre une nouvelle observation et l'hypothèse d'une nouvelle piste. Comme son nom l'indique, cette méthode prend en compte la plus proche mesure pour effectuer la mise à jour de la trajectoire. Le principal inconvénient de la méthode du plus proche voisin tient au fait que la décision sur l'association est immédiate et irrévocable, car elle ignore totalement les autres mesures : l'hypothèse la plus probable est considérée comme vraie. Son principal avantage, outre sa popularité, est son faible coût calculatoire.

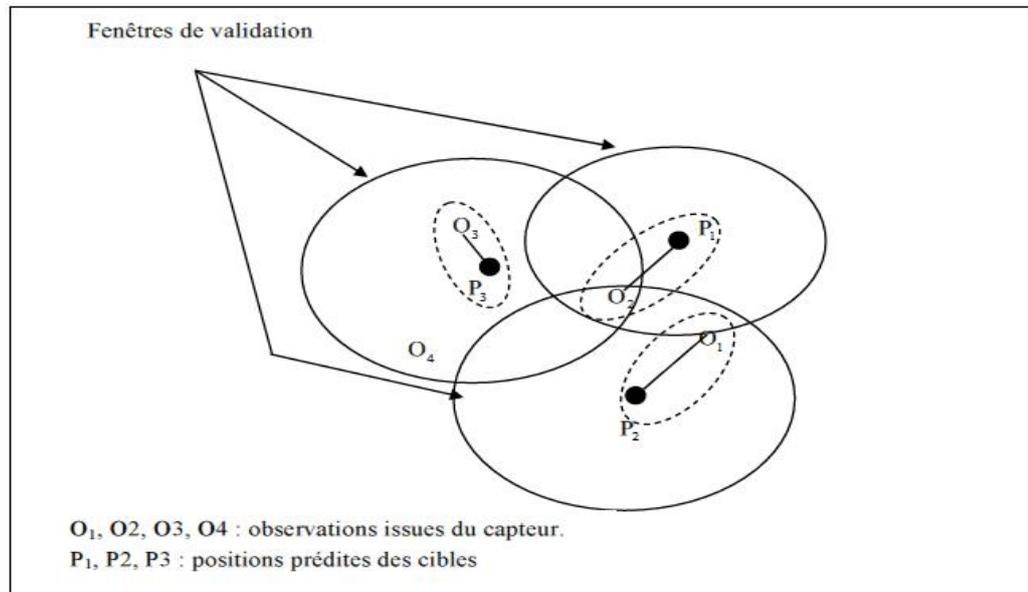


Figure 3.3 : Exemple d'association NN

La figure (3.3) représente une situation utilisant une association de type plus proche voisin : O_3 est associé à P_3 parce qu'en étant le plus proche, de la même manière, O_2 est associé à P_1 , O_1 est associé à P_2 . O_4 n'est associé à aucune cible.

3.4.2. Filtre d'association de données par probabilités conjointes (JPDA)

Le JPDA est une extension du PDA pour la poursuite multi-cibles. Pour cette méthode, le nombre de cibles M est supposé connu et constant. L'estimation de l'état de chaque cible se fait selon un filtre de Kalman comme dans le PDA. La seule différence réside au niveau de l'évaluation des probabilités d'association. La figure (3.4) permet de comprendre de manière intuitive le principe du JPDA dans une situation conflictuelle. Dans cet exemple, deux pistes sont formées et poursuivies.

Les états prédits de ces deux pistes à un instant donné sont représentés par les points P_1 et P_2 , la fenêtre de validation de chacune des pistes est représentée par un cercle centré autour de ces derniers. Les deux fenêtres de validation se chevauchent partiellement. À cet instant, le capteur envoie trois observations. La première est située à l'intérieur de la fenêtre de validation de la première piste uniquement, les deux autres sont situées dans la zone commune aux deux fenêtres de validation. Comme les trois observations sont dans la fenêtre de validation de la première piste, la mise à jour de cette piste se fera en tenant compte de ces trois observations, sous forme d'une somme pondérée par la probabilité d'association de chacune des trois mesures.

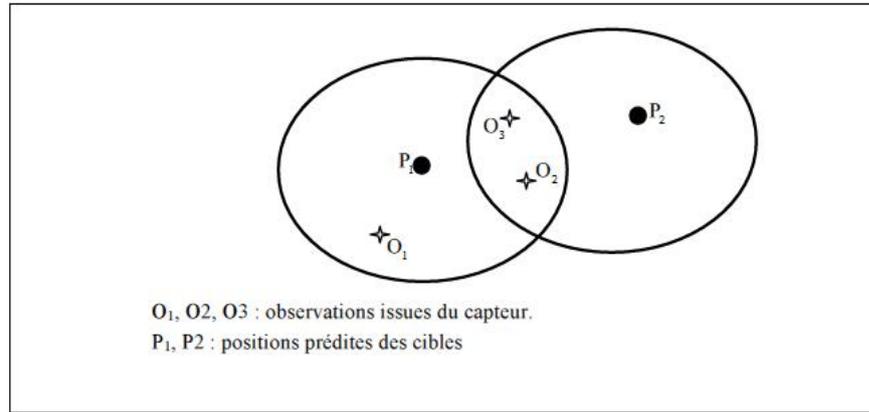


Figure 3.4 : Exemple d'association JPDA

Toutefois, la probabilité d'association, et donc le poids des observations O_2 et O_3 , sera réduite pour tenir compte de leur présence dans la fenêtre de validation de la deuxième piste. La mise à jour de la deuxième piste sera faite en tenant compte des observations O_1 et O_2 .

On a représenté les hypothèses de notre exemple dans le tableau (3.1). La première ligne de ce tableau correspond à l'hypothèse où toutes les mesures sont des fausses alarmes, la deuxième ligne correspond à l'affectation de la mesure N° 3 à la première trajectoire et à deux fausses alarmes.

Tableau 3.1 : Tableau des hypothèses

Hypothèse N°	Traj. N° 1	Traj. N° 1	Fausses alarmes
1	-	-	1, 2, 3
2	1	-	2, 3
3	2	-	1, 3
4	3	-	1, 2
5	-	2	1, 3
6	1	2	3
7	3	2	1
8	-	3	1, 2
9	1	3	2
10	2	3	1

Le JPDA original suppose un nombre connu et constant de pistes. Il a été étendu pour gérer la création et l'élimination de pistes.

La création d'une nouvelle piste est envisagée pour les observations ayant obtenu une faible probabilité d'association avec une piste existante.

Pour chaque piste, et pour chaque tentative de nouvelle piste, la probabilité que cette piste corresponde à une piste existante et la confirmation de nouvelles pistes sont décidées par un seuillage sur cette probabilité.

L'augmentation importante de la puissance de calcul tend à rendre populaire des méthodes utilisant toutes les observations voisines d'une cible pour la mise à jour de l'état de la cible à savoir la méthode JPDA qui a toutefois besoin de beaucoup de ressources pour une implantation matérielle lorsque le nombre de cibles augmente [36]. Afin de contourner cette difficulté, une méthode ad-hoc a été proposée dans [37]. Il s'agit du « *Cheap* » JPDA (CJPDA) introduit pour approximer la probabilité d'association de chaque mesure j à chaque cible i de la manière suivante [37] :

$$\beta_{ij} = \frac{G_{ij}}{S_{ii} + S_{jj} - G_{ij} + b} \quad (3.31)$$

$$G_{ij} = \frac{1}{2\pi\sqrt{|\det(A_{ij})|}} \exp\left(-\frac{1}{2}\mathbf{v}_{ij}^T A_{ij}^{-1} \mathbf{v}_{ij}\right) \quad (3.32)$$

Où \mathbf{v}_{ij} est l'innovation, A_{ij} est la matrice de covariance de \mathbf{v}_{ij} et enfin :

$$S_{ii} = \sum_{j=1}^{N_{OBS}} G_{ij} \quad \text{et} \quad S_{jj} = \sum_{i=1}^{N_{CIB}} G_{ij} \quad (3.33)$$

Avec N_{OBS} représente le nombre de mesures et N_{CIB} est le nombre de cibles.

3.5. Modélisation du Clutter (fouillis) de mer

Nous précisons tout d'abord la signification du terme clutter. On appelle clutter le bruit provoqué par l'énergie renvoyée par des obstacles naturels (terre, mer, atmosphère) qui rend la détection de la cible utile très difficile. Le clutter est constitué soit d'échos atmosphériques soit d'échos situés à la surface de notre planète. Il s'avère particulièrement indispensable de connaître la distribution du clutter pour établir le seuil de détection.

Cette distribution dépend de la nature du clutter ainsi que la résolution du RADAR. Nous distinguons généralement deux types de clutter, le clutter de surface et le clutter de volume. Le clutter de surface est celui qui provient des échos de la mer et de la terre alors que le clutter de volume est dû aux phénomènes atmosphériques.

Ces deux types de clutter sont tels que le rapport du signal sur clutter (Signal to Clutter Ratio, SCR) est très grand par rapport au rapport signal sur bruit (Signal to Noise Ratio, SNR). La présence des interférences induit, quant à elle, un rapport signal à interférence (Signal to interference Ratio, SIR) beaucoup plus grand que le SNR.

Dans notre travail on va utiliser un clutter (fouillis) de mer de distribution de Weibull (voir appendice A), on le présente brièvement dans ce paragraphe.

- Clutter de mer

Il est bien connu que l'amplitude du clutter de mer est distribuée selon une loi de Weibull (voir appendice A), la distribution de Weibull introduite par Schleher [38] pour modéliser le clutter de mer. La distribution de Weibull dépend de deux paramètres, le paramètre de forme et le paramètre d'échelle. La densité de probabilité est exprimée comme suit [39] :

$$f_x(x) = \frac{\beta}{\alpha} \left(\frac{x}{\alpha}\right)^{\beta-1} \exp\left[-\left(\frac{x}{\alpha}\right)^\beta\right], \alpha > 0, \beta > 0 \quad (3.34)$$

α représente le paramètre d'échelle et β le paramètre de forme de la distribution de Weibull.

3.6. Simulation numérique

- Modèles de mouvement
- Modèle M1 Mouvement rectiligne à vitesse constante [26] (voir paragraphe 2.6).
- Modèle M2 Mouvement circulaire à vitesse de rotation constante.

Dans ce modèle, la vitesse de rotation ω de la cible est inconnue. Ainsi, cette vitesse devient un paramètre important à estimer. Pour cela, il est nécessaire d'augmenter la taille du vecteur, donné par (2.31), qui devient :

$$\underline{X}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k, w_k]^T \quad (3.35)$$

Par conséquent, nous ne pouvons plus utiliser la fonction de transition et la matrice de commande précédente. Celles-ci doivent être changées. Elles sont données par les expressions suivantes [26] :

$$f_2(\underline{X}_k) = \begin{bmatrix} 1 & \sin(\underline{X}_{5,k}T)/\underline{X}_{5,k} & 0 & -(1 - \cos(\underline{X}_{5,k}T))/\underline{X}_{5,k} & 0 \\ 0 & \cos(\underline{X}_{5,k}T) & 0 & -\sin(\underline{X}_{5,k}T) & 0 \\ 0 & (1 - \cos(\underline{X}_{5,k}T))/\underline{X}_{5,k} & 1 & \sin(\underline{X}_{5,k}T)/\underline{X}_{5,k} & 0 \\ 0 & \sin(\underline{X}_{5,k}T) & 0 & \cos(\underline{X}_{5,k}T) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.36)$$

$$G_2 = \begin{bmatrix} T^2/2 & 0 & 0 \\ T & 0 & 0 \\ 0 & T^2/2 & 0 \\ 0 & T & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.37)$$

- Nous venons de voir dans les paragraphes précédents les notions relatives aux modèles d'état d'une cible, l'EKF ainsi que deux autres méthodes d'association de données NN et JPDA. L'algorithme dans la figure (3.5) résume le principe de poursuite de cibles par les différentes méthodes d'association DST, NN et JPDA.

- **Initialisation** : pour chaque cible tr ($tr = 1, \dots, N_{CIB}$) :
 - choisir l'état initial $\hat{\underline{X}}_{tr,0}$
 - initialiser la matrice de covariance $P_{tr,0}$.
- **Filtrage** : application de l'EKF pour l'estimation d'état selon les étapes suivantes
 - Prédiction
 - Association de données par l'une des méthodes JPDA, NN ou CD
 - Association par **JPDA**.
 - Fenêtrage : sélectionner les mesures qui sont à l'intérieur de la fenêtre de validation de la cible tr ,
 - calculer pour chaque mesure $\underline{Z}_z(k)$ ($z=1, \dots, m(k)$), $\beta_{tr,z}$: les probabilités d'association, et $\beta_{tr,0}$: la probabilité de la non association.
 - Association par **NN**.
 - trouver l'observation ayant la distance euclidienne minimale avec l'observation prédite.
 - Association par **CD**.
 - trouver l'observation ayant le maximum de crédibilité avec l'observation prédite après la combinaison.
 - Mise à jours de l'état et de la matrice de covariance : calcul de $\hat{\underline{X}}_{tr,k}$ et $P_{tr,k}$
 - ❖ après l'association par **JPDA**

$$1. \hat{\underline{X}}_{tr,k/k} = \hat{\underline{X}}_{tr,k/k-1} + K_k \text{Inov}^{tr}(k) \text{ où } \begin{cases} \text{Inov}^{tr}(k) = \sum_{z=1}^{m(k)} \beta_{tr,z}(k) \text{Inov}_z^{tr}(k) \\ \text{Inov}_z^{tr}(k) = \underline{Z}_z(k) - h(\hat{\underline{X}}_{tr,k/k-1}) \end{cases}$$

$m(k)$ est le nombre de mesures validées à l'instant k .

$$2. P_{tr,k/k} = \beta_{tr,0} P_{tr,k/k-1} + (1 - \beta_{tr,0}) \left[P_{tr,k/k-1} - K_k H(\hat{\underline{X}}_{tr,k/k-1}) P_{tr,k/k-1} \right] + \mathcal{P}_{tr,k}^0$$

Où

$$\mathcal{P}_{tr,k}^0 = K_k \left(\sum_{z=1}^{m(k)} \beta_{tr,z}(k) \text{Inov}_z^{tr}(k) \text{Inov}_z^{tr}(k)^T - \text{Inov}^{tr}(k) \text{Inov}^{tr}(k)^T \right) K_k^T$$

- ❖ après l'association par **NN**

$$\hat{\underline{X}}_{tr,k/k} = \hat{\underline{X}}_{tr,k/k-1} + K_k \left[\underline{Z}_k^{NN} - \underline{Z}_{tr,pk} \right], \quad \underline{Z}_{tr,pk} = h(\hat{\underline{X}}_{tr,k/k-1})$$

$$P_{tr,k/k} = P_{tr,k/k-1} - K_k H(\hat{\underline{X}}_{tr,k/k-1}) P_{tr,k/k-1}$$

\underline{Z}_k^{NN} : L'observation ayant la distance euclidienne minimale avec l'observation prédite $\underline{Z}_{tr,pk}$.

- ❖ après l'association par **CD**

$$\hat{\underline{X}}_{tr,k/k} = \hat{\underline{X}}_{tr,k/k-1} + K_k \left[\underline{Z}_k^{CD} - \underline{Z}_{tr,pk} \right], \quad \underline{Z}_{tr,pk} = h(\hat{\underline{X}}_{tr,k/k-1})$$

$$P_{tr,k/k} = P_{tr,k/k-1} - K_k H(\hat{\underline{X}}_{tr,k/k-1}) P_{tr,k/k-1}$$

\underline{Z}_k^{CD} : L'observation ayant le maximum de crédibilité avec l'observation prédite $\underline{Z}_{tr,pk}$.

Figure 3.5 : L'algorithme (JPDA, NN, CD)-EKF

- Nous étudions dans ce paragraphe les performances de la poursuite de plusieurs cibles en utilisant notre méthode d'association de données par combinaison de Dempster (CD) et d'autres méthodes d'association de données NN et JPDA présentées antérieurement.
- Afin de comparer les performances de la poursuite de cibles (sans changement de modèles) en utilisant les NN, le JPDA et CD, nous considérons deux scénarios possibles :
 - Scénario Sc1 : Trois cibles parallèles
 - Scénario Sc2 : Trois cibles qui se croisent
- **Scénario Sc1** afin de tester la robustesse des méthodes d'association de données vis-à-vis du risque de confusion permanent (durant tout le trajet), nous considérons le cas de trois cibles qui suivent le modèle M1 et évoluent selon des trajectoires parallèles.
- **Scénario Sc2** afin de tester la robustesse des méthodes d'association de données vis-à-vis du risque de confusion lors du croisement, nous considérons deux cibles qui suivent le modèle M1 et une cible qui suit le modèle M2.
- Pour étudier les performances, nous allons effectuer 100 réalisations indépendantes de Monte-Carlo (voir Appendice B) [40], afin d'évaluer les performances suivantes :
 - L'erreur quadratique moyenne en position REQMP
 - L'erreur quadratique moyenne en vitesse REQMV
 - Probabilités d'association
- Afin de comparer ces performances, nous allons considérer différentes situations :
 - Situation S1 : poursuite sans présence de clutter
 - Situation S2 : poursuite avec présence de clutter de mer (voir appendice A)

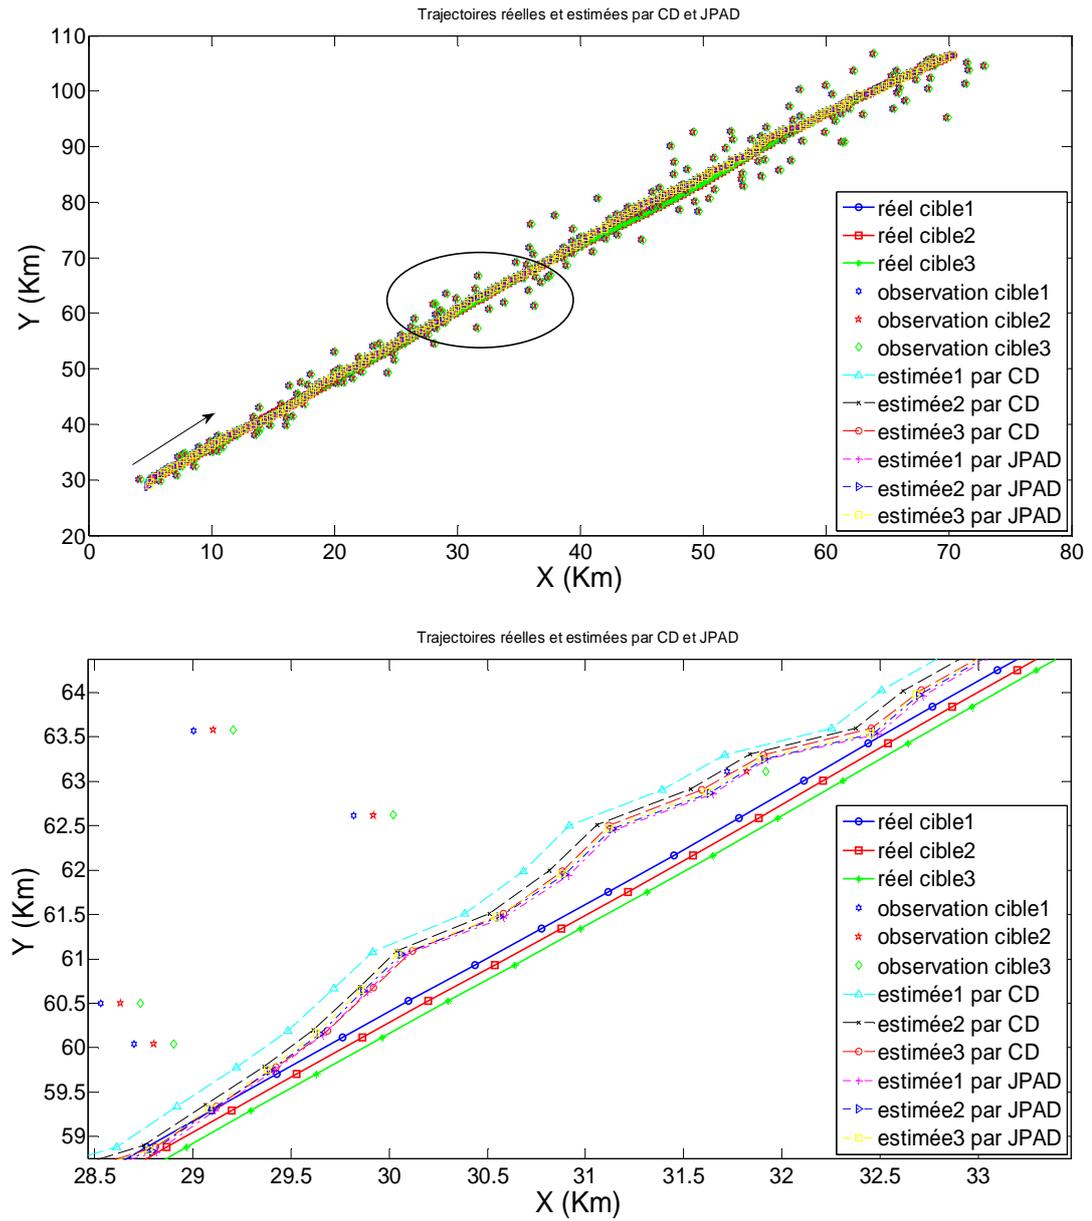


Figure 3.6 : Trajectoires réelles et estimées par CD et JPDA pour (S1, Sc1)

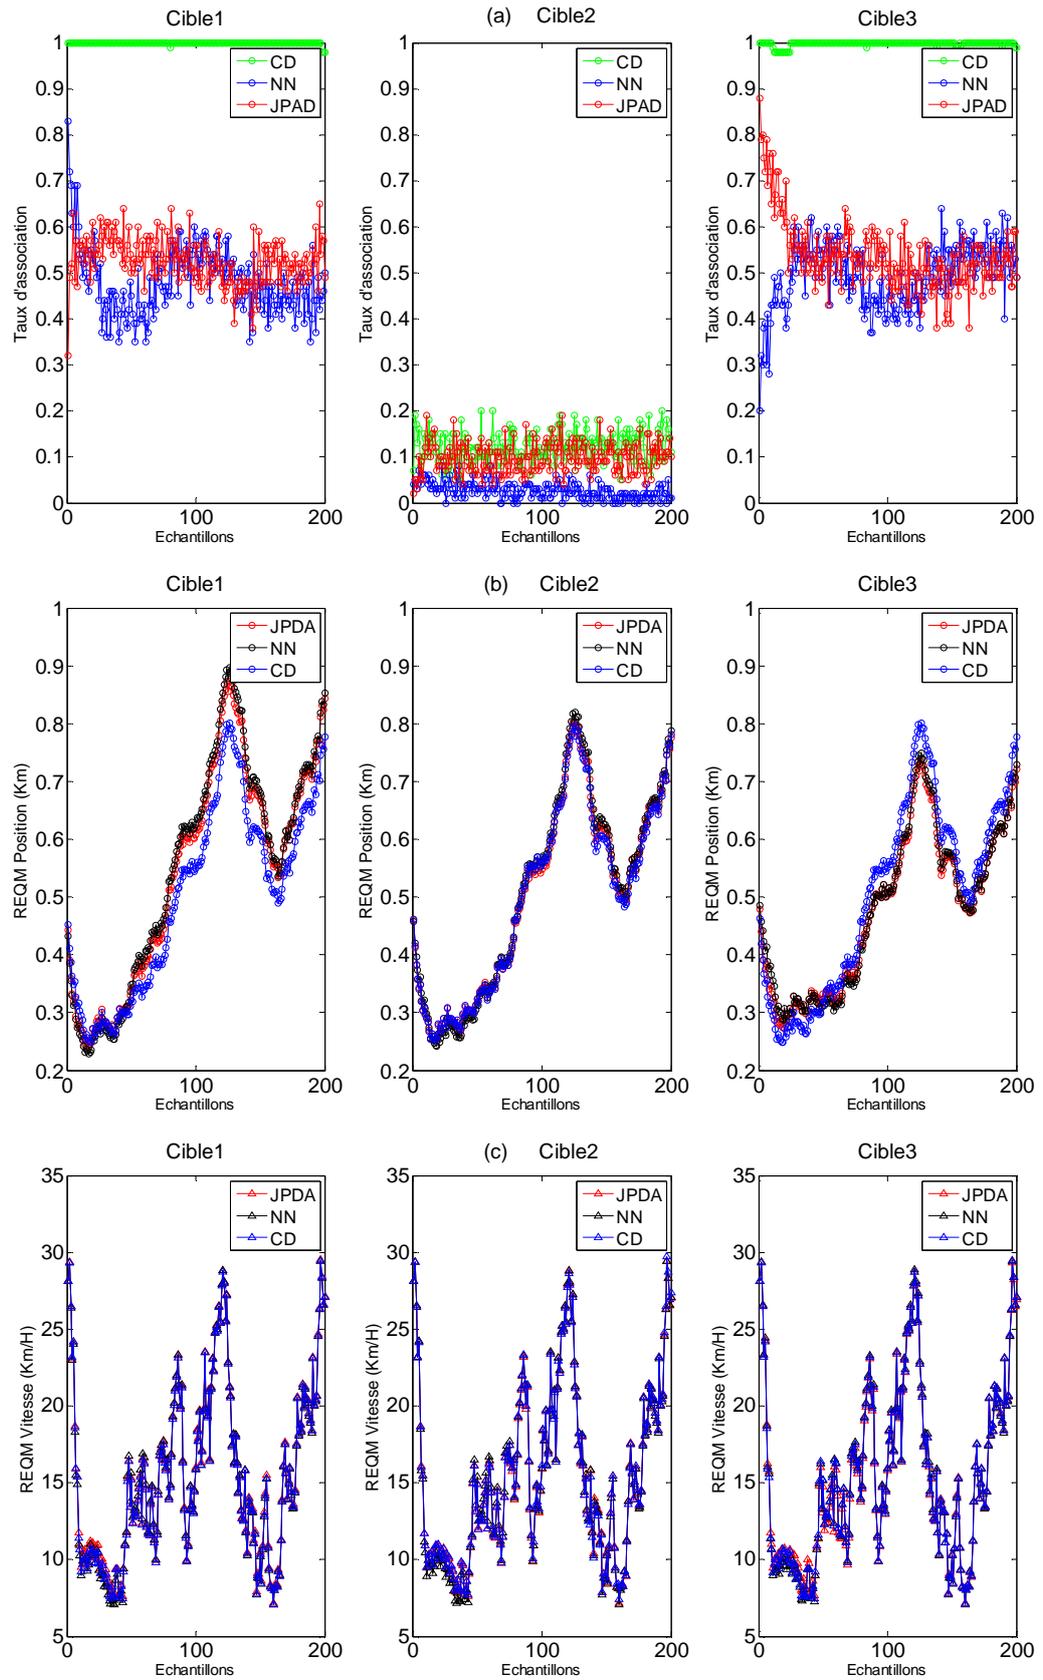


Figure 3.8 : Les mesures de performances CD, NN et JPDA pour (S1, Sc1)
 (a) taux d'association (b) REQM P (c) REQM V

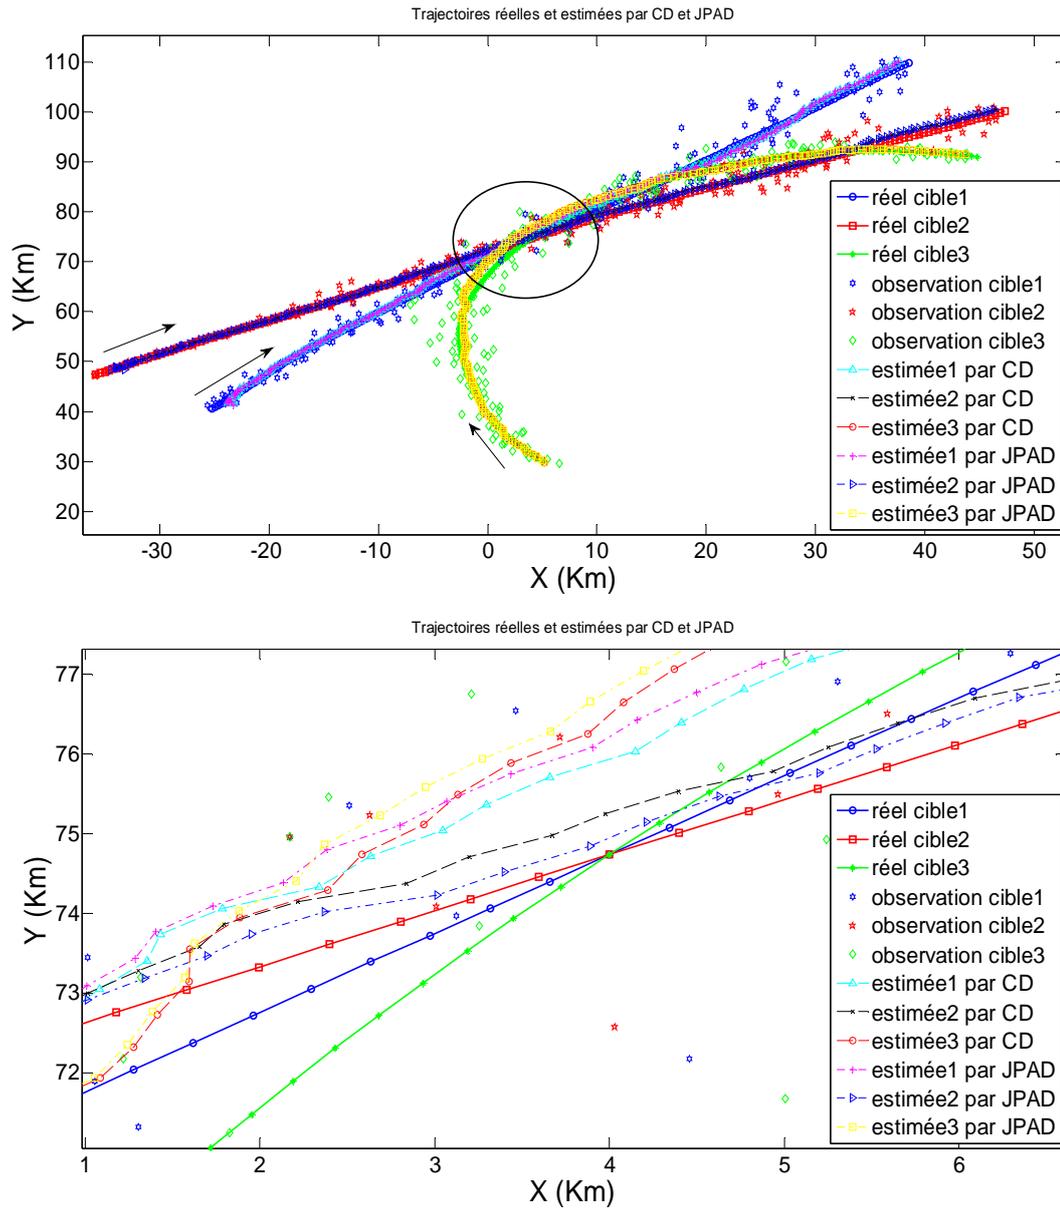


Figure 3.9 : Trajectoires réelles et estimées par CD et JPDA pour (S1, Sc2)

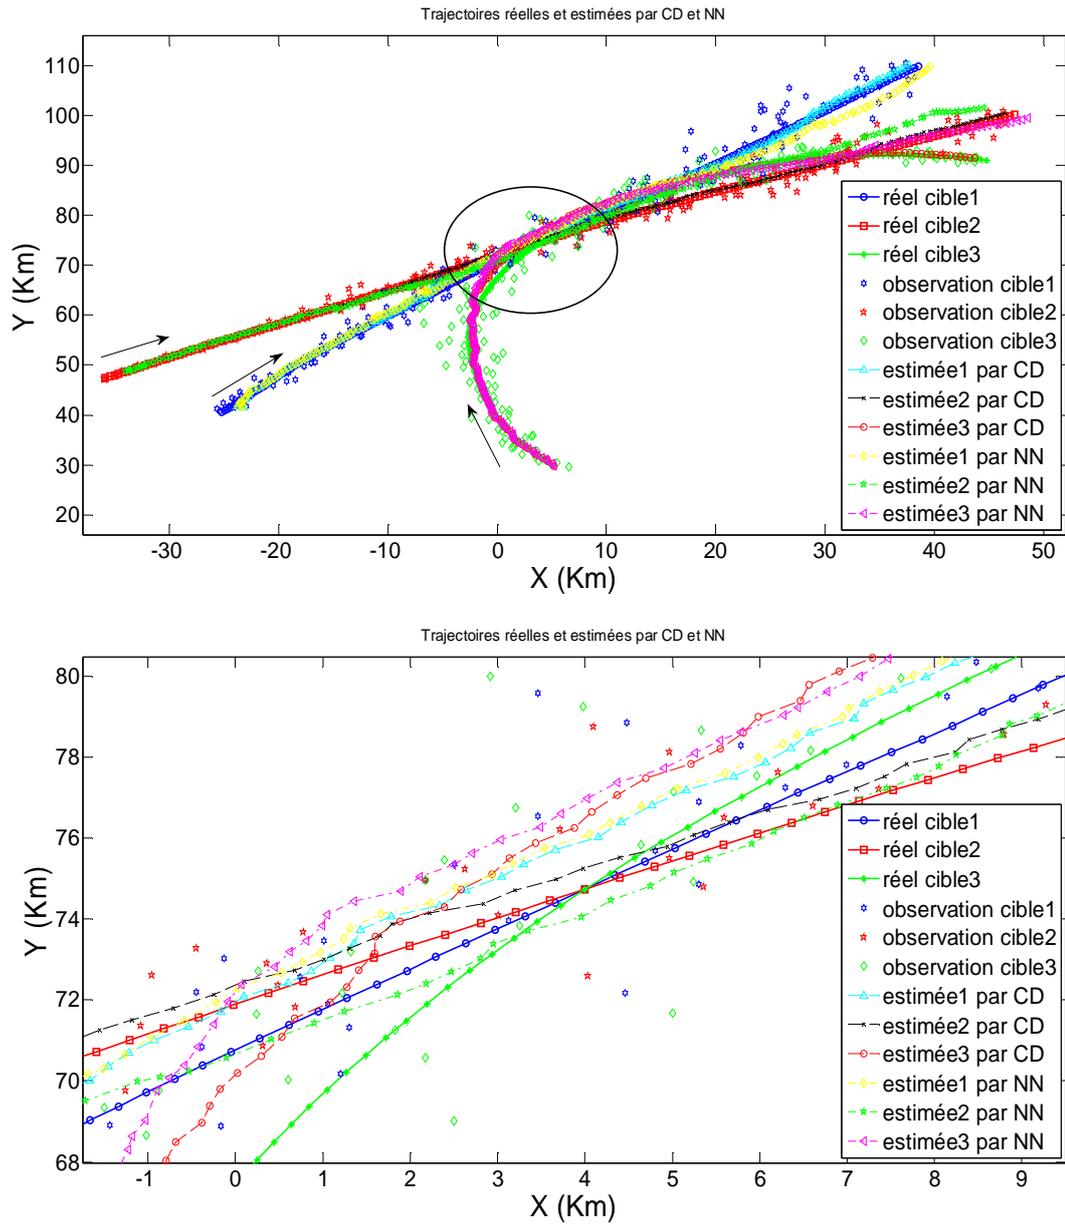


Figure 3.10 : Trajectoires réelles et estimées par CD et NN pour (S1, Sc2)

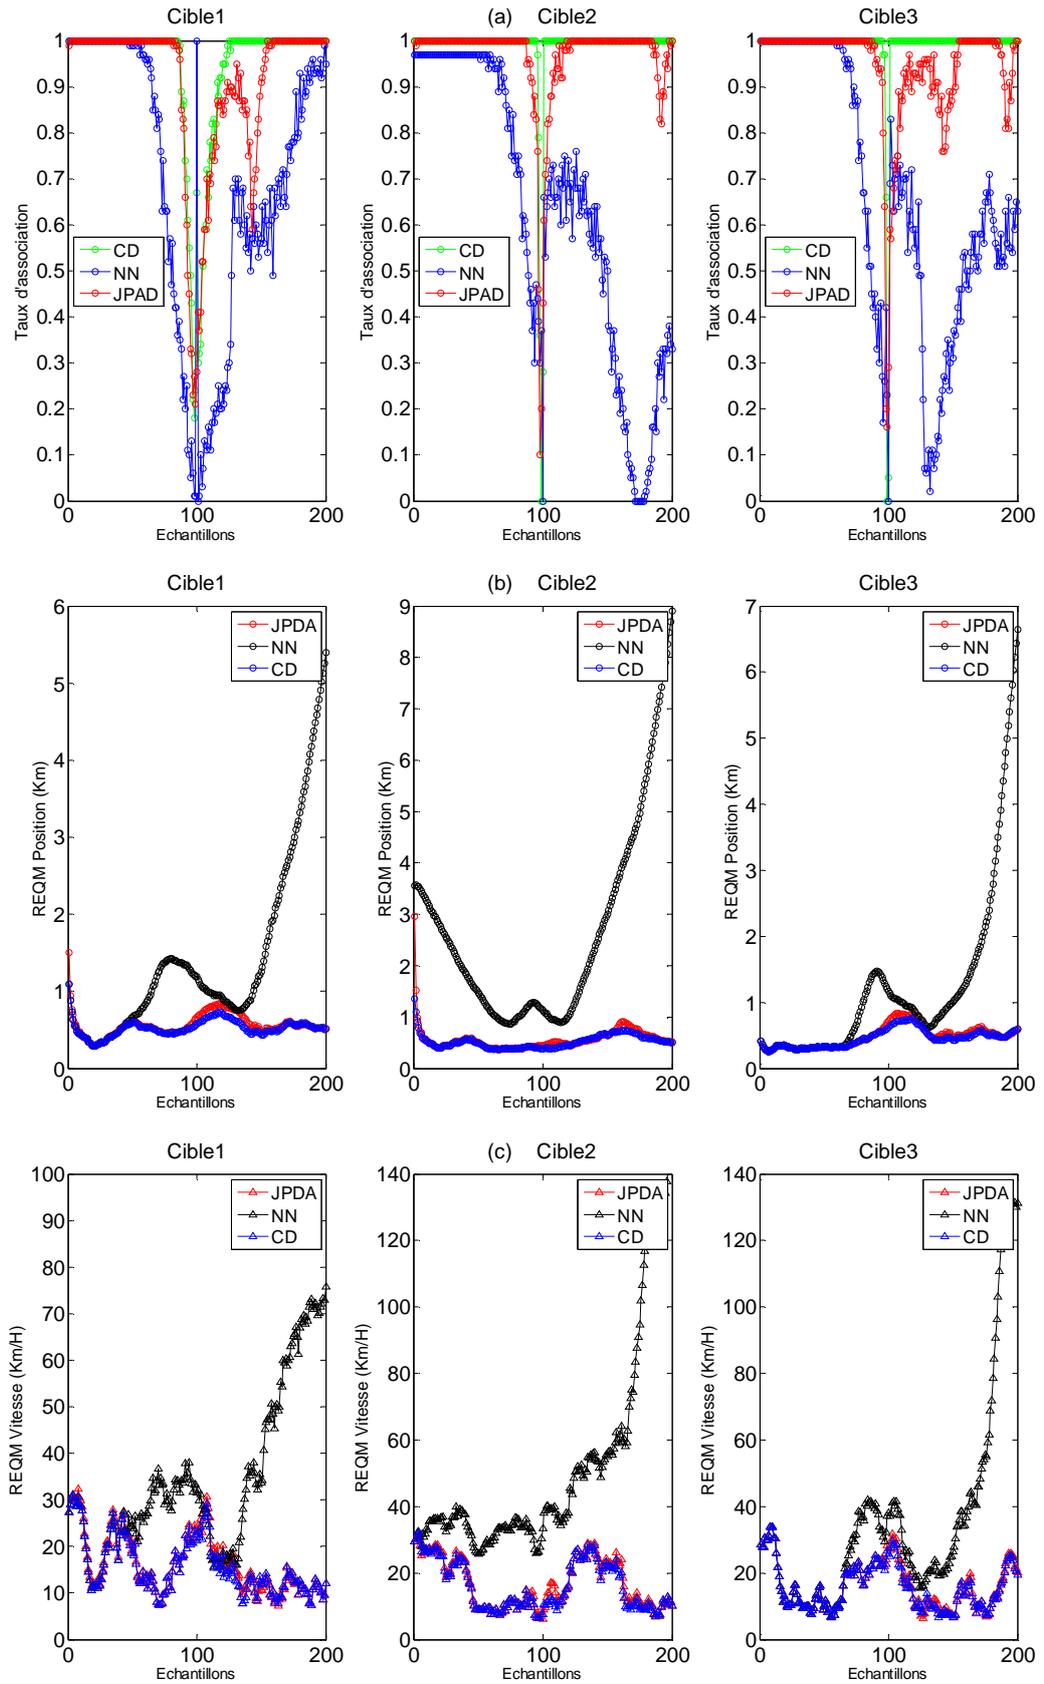


Figure 3.11 : Les mesures de performances CD, NN et JPDA pour (S1, Sc2)
 (a) taux d'association (b) REQM P (c) REQM V

Dans cette simulation nous avons étudié les performances de la poursuite multi-cibles sans la présence de clutter (S1) des différentes méthodes d'association CD, NN et JPDA les résultats obtenus permettent de dégager les remarques suivantes :

- Scénario Sc1 (trois cibles parallèles)
- Les trajectoires estimées par CD sont très proches des trajectoires réelles et la séparation entre les cibles est évidente, il n'y a pas de confusion entre les cibles durant tout le trajet, les trajectoires estimées par JPDA sont très proche des trajectoires réelles, mais la séparation entre les cibles est moins bonne que CD, les trajectoires estimées par NN sont proches de trajectoires réelles, mais la séparation entre les cibles est très faible.
- La méthode CD présente de meilleures performances en termes de taux d'association que JPDA et NN (la probabilité d'association décroît drastiquement pour la deuxième cible parce qu'elle évolue entre deux cibles).
- Les REQMP et REQMV des différentes méthodes sont très proches, pour cela nous avons calculé : $(REQMP(CD) = 3.0024 \cdot 10^5 \text{ m})$, $(REQMP(JPDA) = 3.1974 \cdot 10^5 \text{ m})$, $(REQMP(NN) = 1.0607 \cdot 10^6 \text{ m})$, $(REQMV(CD) = 2.6417 \cdot 10^3 \text{ km/h})$, $(REQMV(JPDA) = 2.7228 \cdot 10^3 \text{ km/h})$, $(REQMV(NN) = 6.8326 \cdot 10^3 \text{ km/h})$
Les performances obtenues en termes de REQMP et REQMV, en utilisant CD sont meilleures que JPDA et NN.

- Scénario Sc2 (trois cibles qui se croisent)
- Les trajectoires estimées par les trois méthodes sont proches des trajectoires réelles, le point d'intersection entre les cibles estimées par CD est proche du point d'intersection réel par contre le point d'intersection estimé par NN et JPDA est un peu loin.
- Lorsque les cibles se croisent, les performances en termes de REQMP et REQMV en utilisant NN sont les plus mauvaises, les performances en termes de REQMP et REQMV en utilisant JPDA sont moins bonnes que CD.
- Les performances en termes de probabilités de bonne association en utilisant CD sont meilleures que JPDA et NN, le taux d'association chute à 0 dans le point de croisement, mais il reprend vite sa valeur initiale par la méthode de CD alors qu'il reprend moins bien pour JPDA et mauvais pour NN.

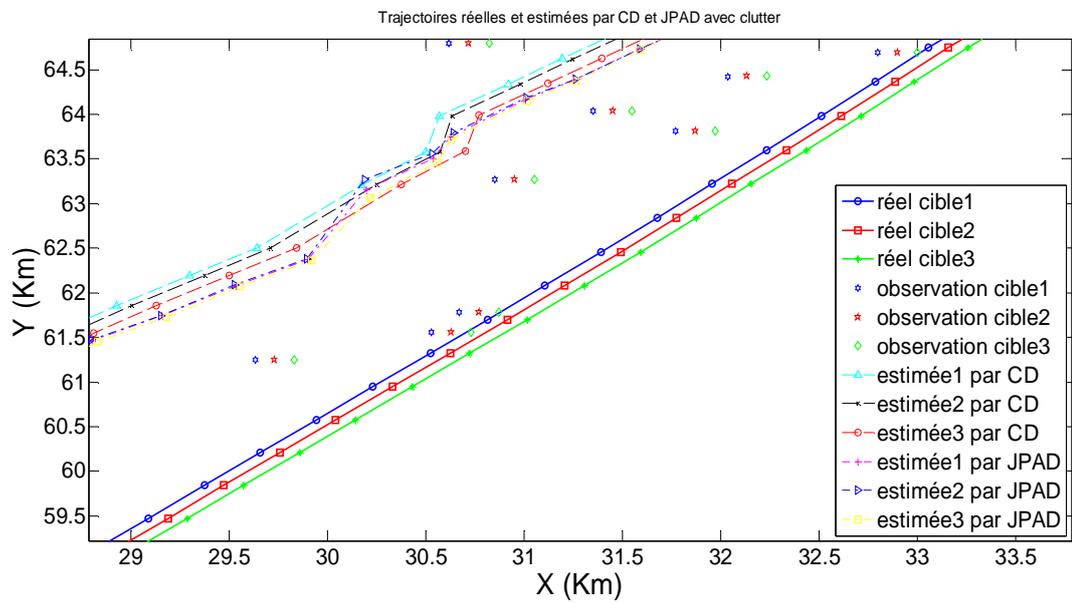
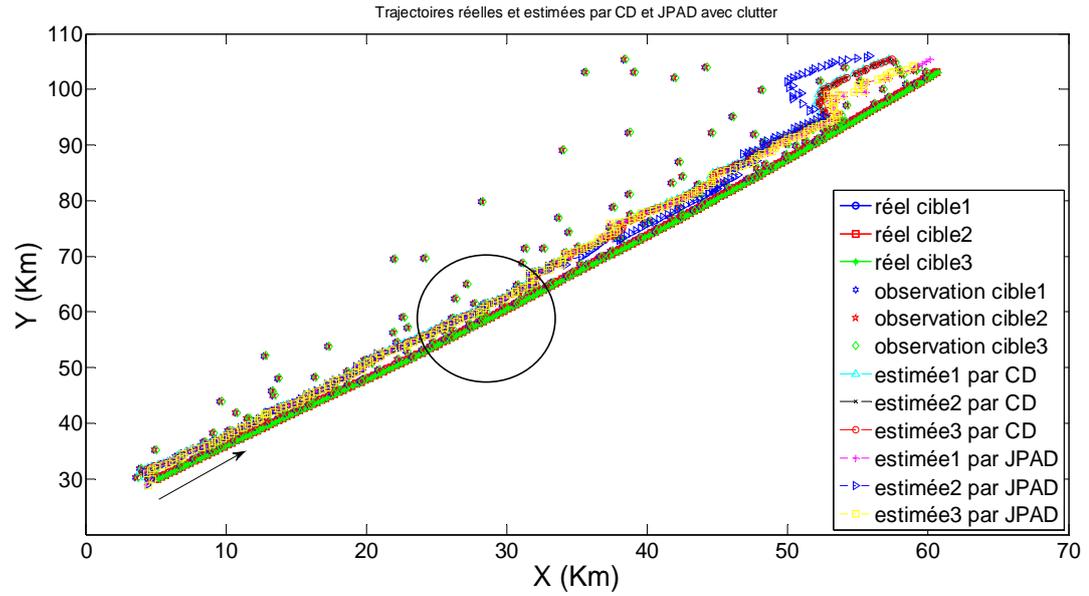


Figure 3.12 : Trajectoires réelles et estimées par CD et JPDA pour (S2, Sc1)

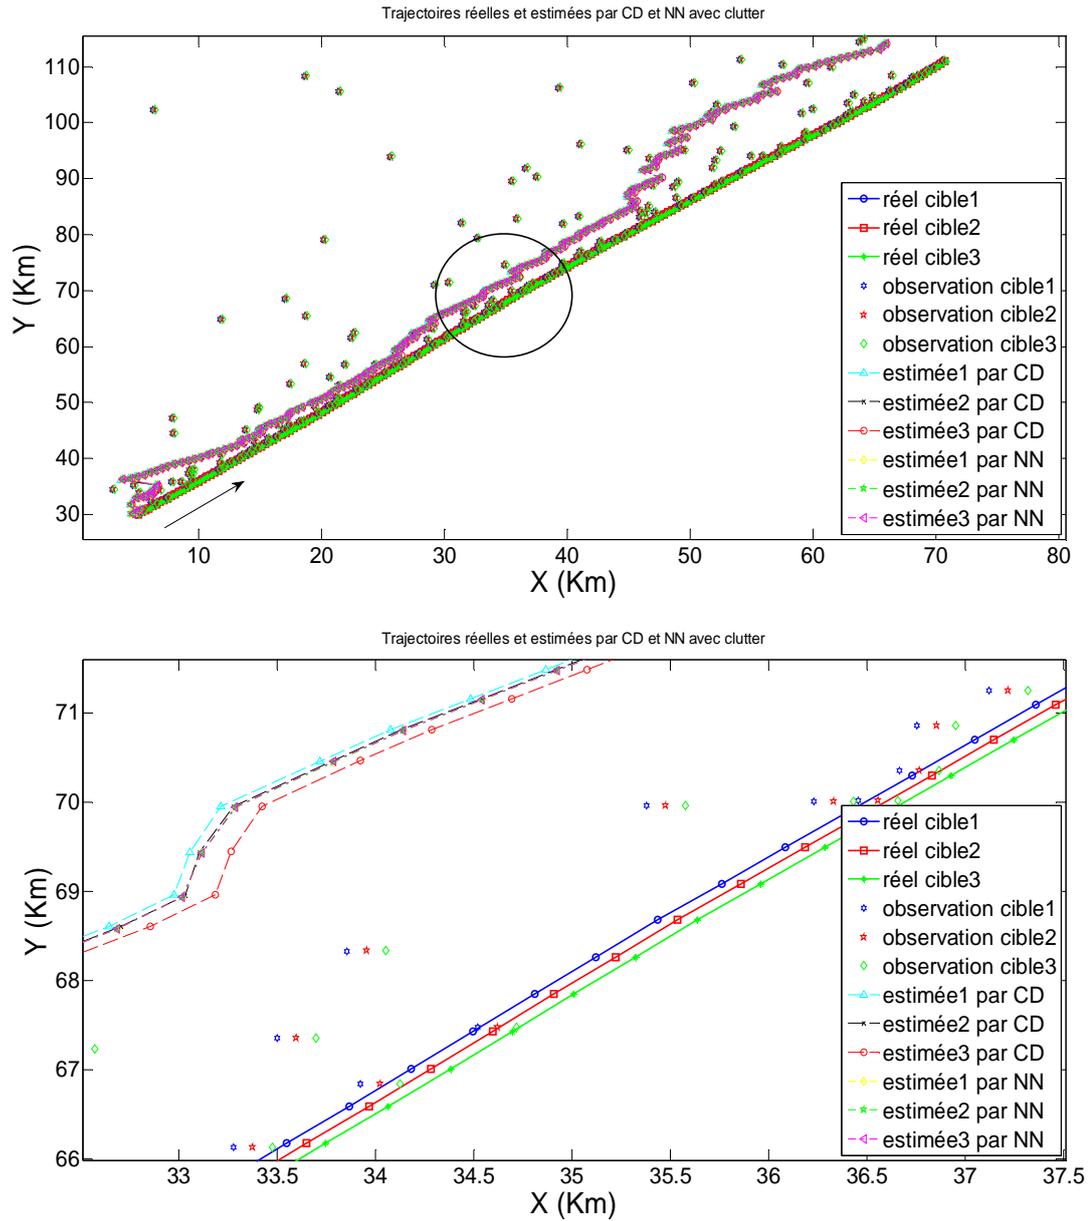


Figure 3.13 : Trajectoires réelles et estimées par CD et NN pour (S2, Sc1)

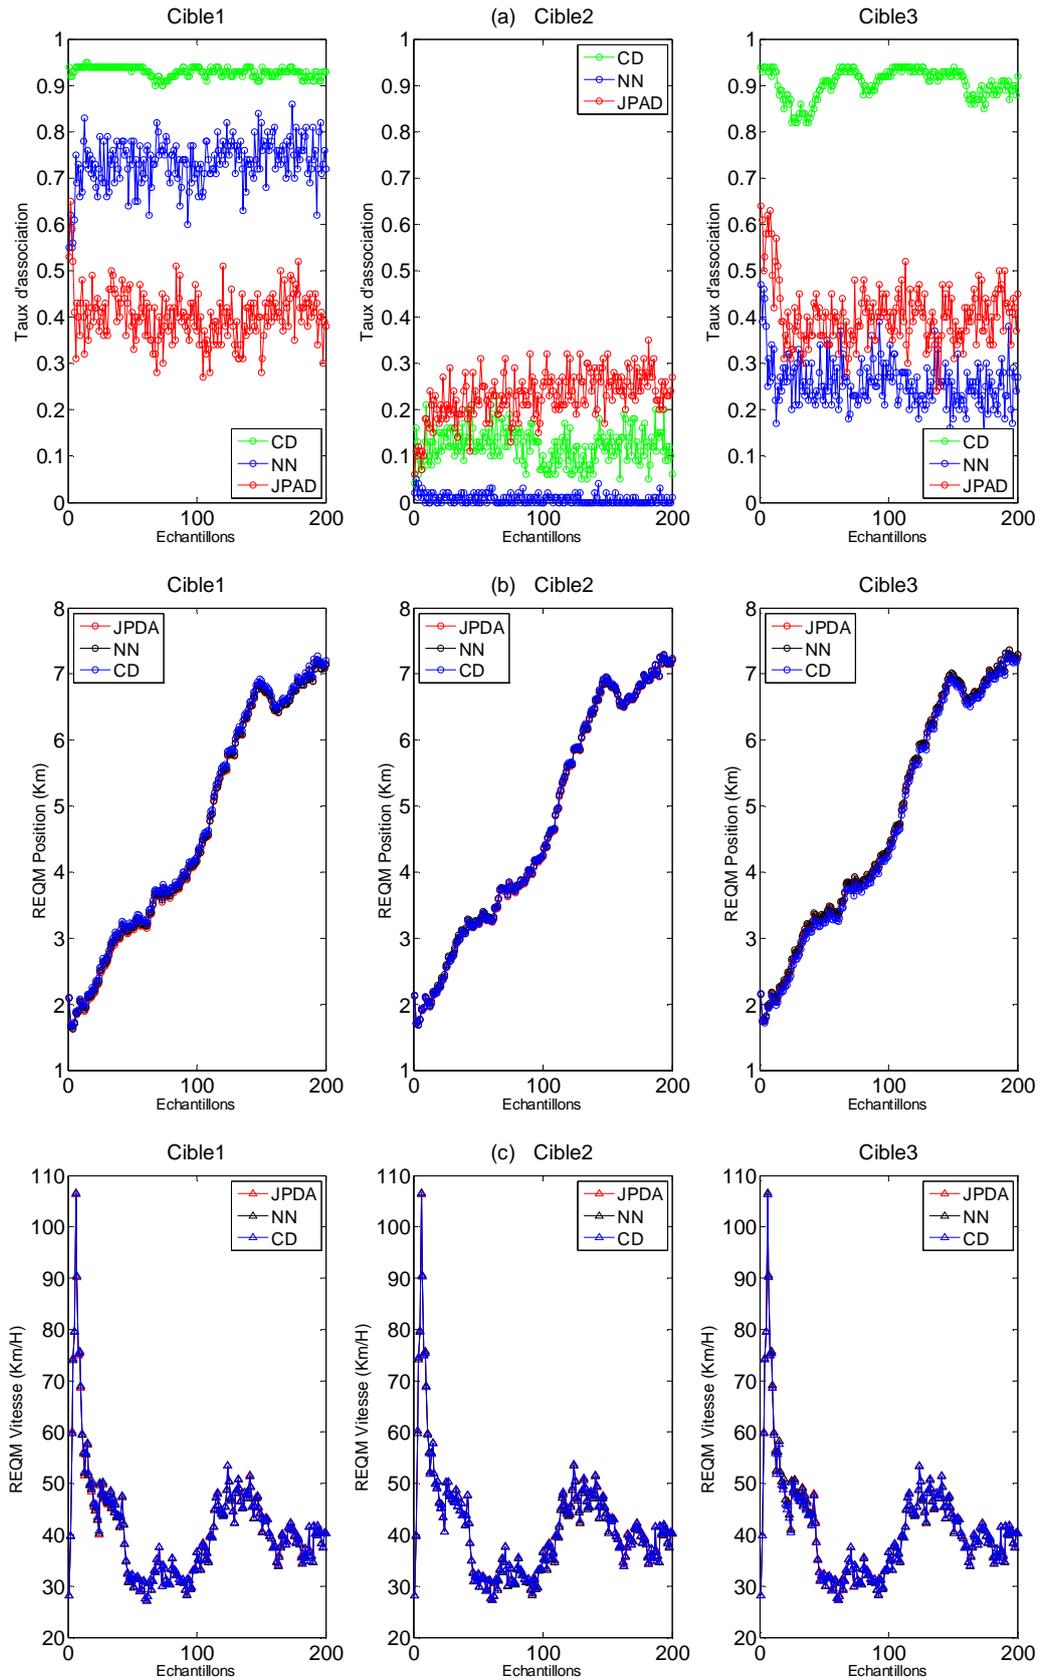


Figure 3.14 : Les mesures de performances CD, NN et JPDA pour (S2, Sc1)
 (a) taux d'association (b) REQM P (c) REQM V

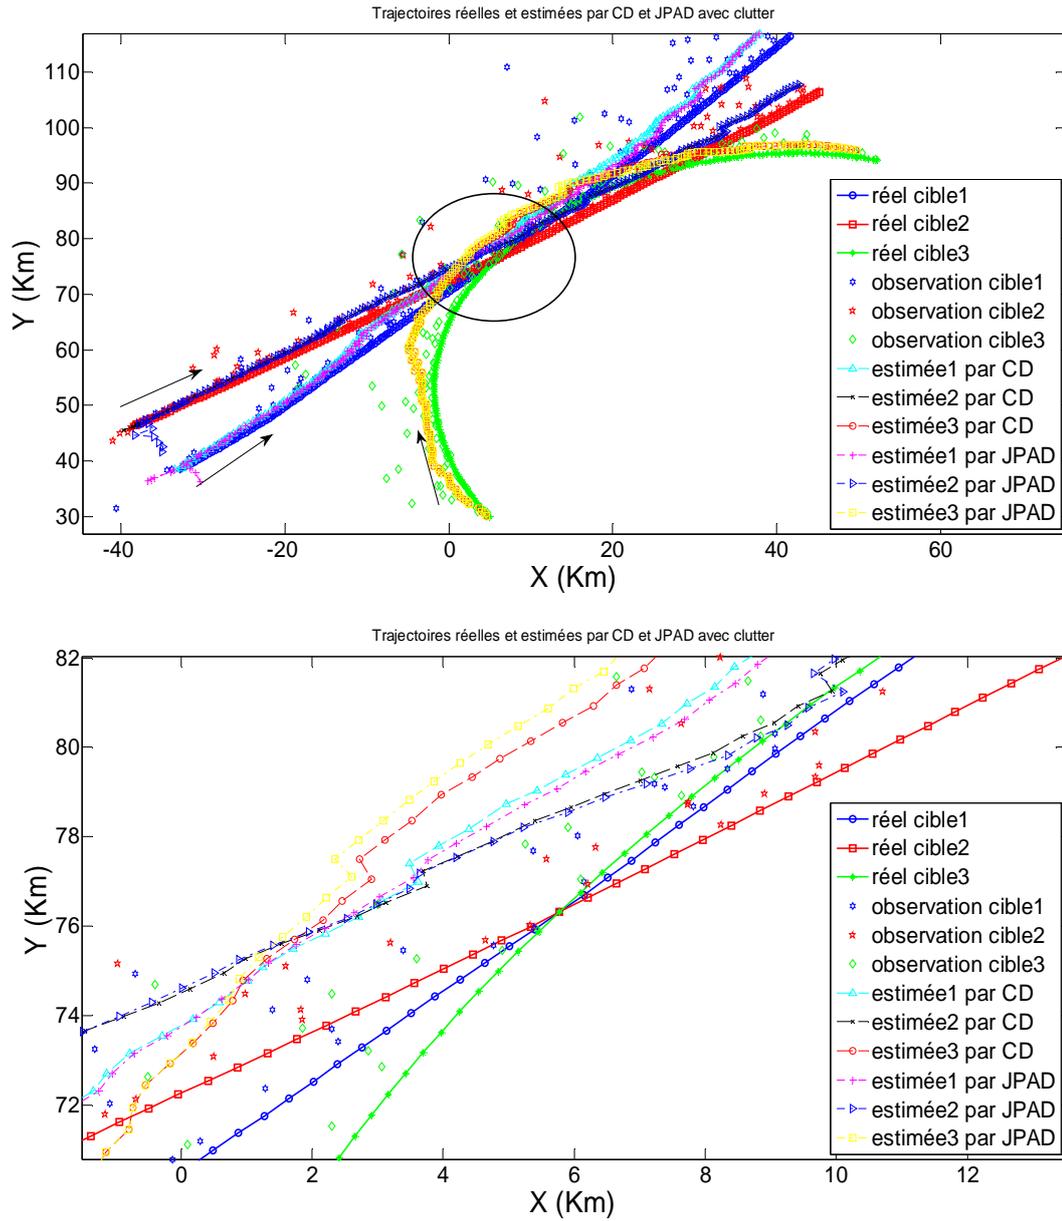


Figure 3.15 : Trajectoires réelles et estimées par CD et JPDA pour (S2, Sc2)

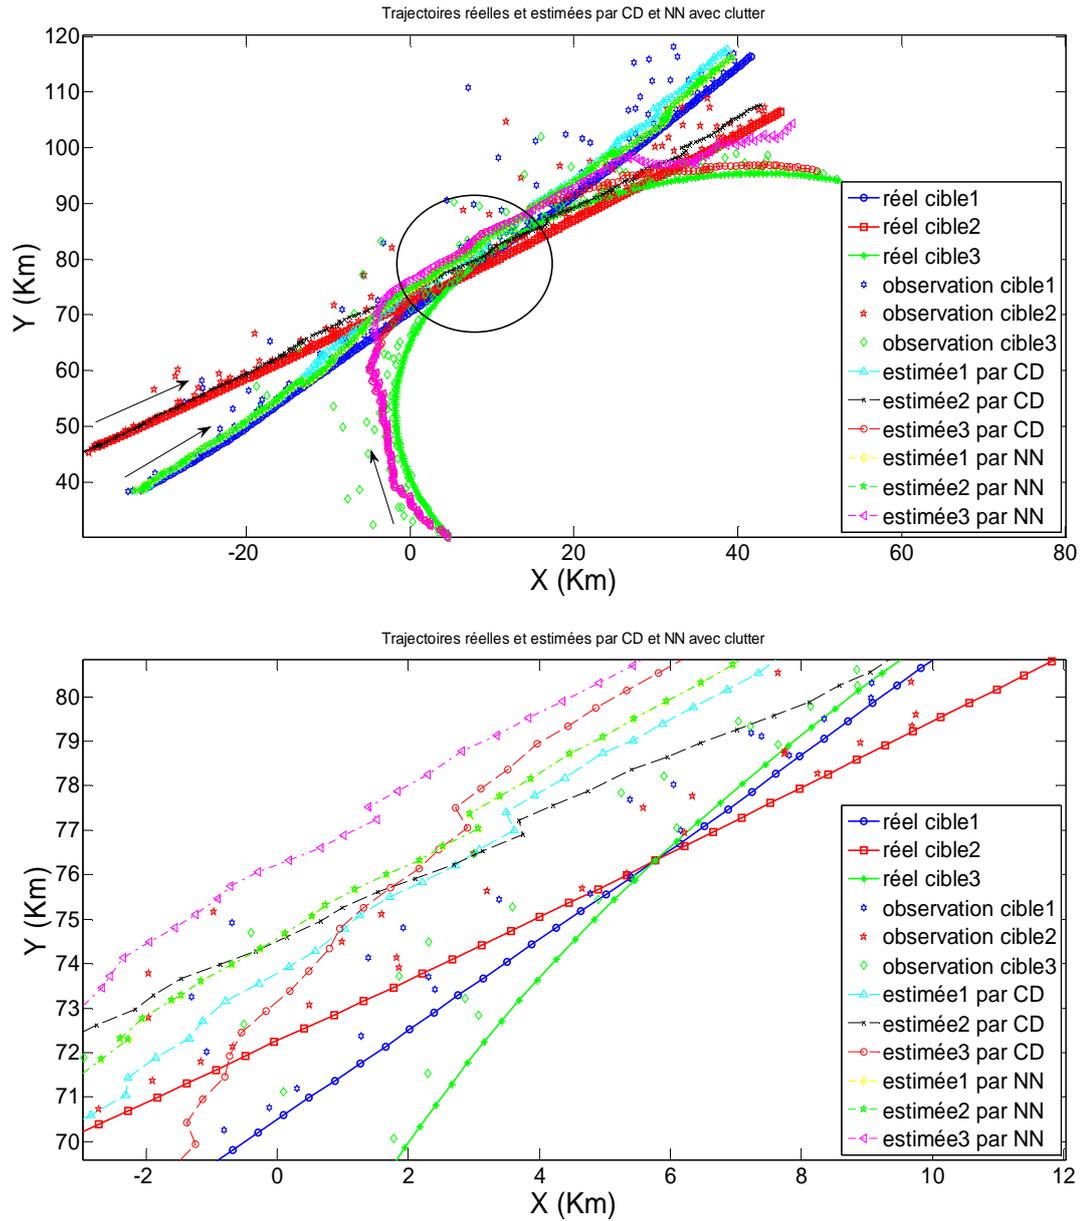


Figure 3.16 : Trajectoires réelles et estimées par CD et NN pour (S2, Sc2)

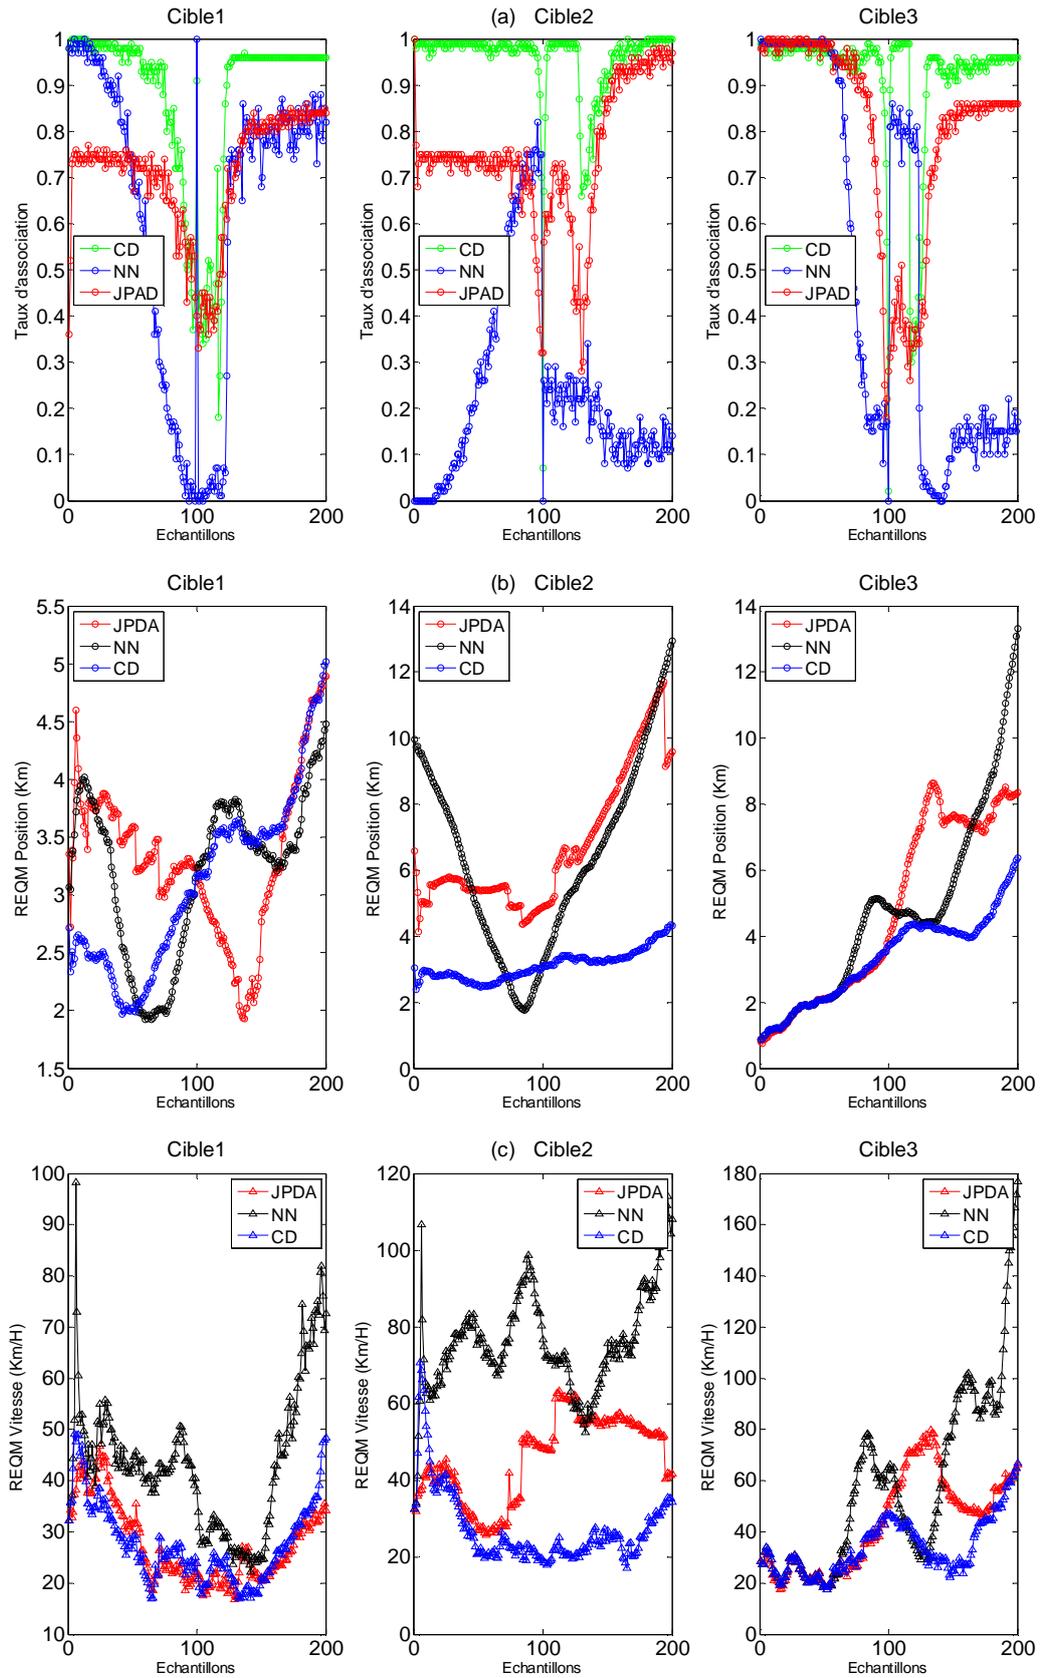


Figure 3.17 : Les mesures de performances CD, NN et JPDA pour (S2, Sc2)
 (a) taux d'association (b) REQM P (c) REQM V

Dans cette simulation nous avons étudié les performances de la poursuite multi-cibles avec la présence de clutter de mer (S2) (distribution de Weibull) (Appendice A) des différentes méthodes d'association CD, NN et JPDA les résultats obtenus permettent de dégager les remarques suivantes :

- Scénario Sc1 (trois cibles parallèles)
- Les trajectoires estimées par CD, NN et JPDA sont un peu loin des trajectoires réelles, la séparation entre les cibles est évidente il n'y a pas de confusion entre les cibles durant tout le trajet estimé par CD, ce qui explique une bonne association de données. La séparation entre les cibles est moins bonne pour JPDA tandis qu'il y a une confusion entre les cibles pour la méthode NN.
- La méthode CD présente de meilleures performances en termes de taux d'association que JPDA et NN (la probabilité d'association chute pour la deuxième cible parce qu'elle évolue entre deux cibles).
- Les REQMP et REQMV des différentes méthodes sont très proches pour cela nous avons calculé : $(REQMP(CD) = 2.8328 \cdot 10^6 \text{ m}, REQMP(JPDA) = 2.8283 \cdot 10^6 \text{ m}, REQMP(NN) = 2.8394 \cdot 10^6 \text{ m})$ $(REQMV(CD) = 6.8652 \cdot 10^3 \text{ km/h}, REQMV(JPDA) = 6.8901 \cdot 10^3 \text{ km/h}, REQMV(NN) = 6.8922 \cdot 10^3 \text{ km/h})$
Les performances obtenues en termes de REQMP et REQMV, en utilisant CD sont légèrement meilleures par rapport aux JPDA et NN.

- Scénario Sc2 (trois cibles qui se croisent)
- Les trajectoires estimées par CD, NN et JPDA sont un peu loin des trajectoires réelles, le point d'intersection des trajectoires estimées par CD et JPDA est proche du point d'intersection réel, il y a une confusion entre la deuxième et la troisième cible pour NN.
- Les performances obtenues en termes REQMP et REQMV en utilisant CD sont meilleures que NN et JPDA.
- Les performances en termes de probabilités de bonne association en utilisant CD sont meilleures que JPDA et NN et une dégradation de taux d'association de S2 par rapport à S1 est observées.

3.7. Conclusion

Dans ce chapitre, nous avons effectué une étude sur la poursuite de cibles non manoeuvrantes avec et sans la présence de clutter par le filtre de Kalman étendu pour la prédiction et l'estimation des états de cibles. Nous avons comparé les performances en termes d'erreur quadratique moyenne en position et en vitesse, de probabilités de bonne association et en trajectoires estimées par différentes méthodes d'association NN, JPDA, et par la méthode de combinaison de Dempster CD. Les résultats de simulation nous permettent de tirer les conclusions suivantes :

- Les performances obtenues en termes de REQM de position et de vitesse en utilisant la méthode CD sont les meilleures par rapport aux méthodes NN et JPDA dans les divers scénarios.
- Les REQM des différentes approches augmentent lorsque l'initialisation s'éloigne du vrai état.
- La méthode NN est à déconseiller dans la situation où les cibles se croisent.
- Les trajectoires estimées par CD sont les meilleurs par rapport aux NN et JPDA il n'y a pas de confusion entre les cibles durant tout le trajet et lors des intersections lorsque les cibles se croisent.
- Les performances obtenues en termes de probabilités de bonne association en utilisant la méthode CD sont meilleures par rapport aux méthodes NN et JPDA dans les divers scénarios.
- La qualité de l'association obtenue par CD est très satisfaisante, le taux d'association obtenue par CD est aux alentours de 1 sauf pour : cibles qui évoluent entre deux cibles, les points de croisement et lors de présence de clutter.
- L'association de données par CD présente une supériorité des performances dans le cas de la présence d'un clutter. La méthode d'association de données par CD reste la plus robuste.

La poursuite de cibles non manoeuvrantes n'est pas un cas courant, pour cela dans le chapitre suivant on va traiter le cas des cibles qui changent leurs modèles de mouvements.

CHAPITRE 4

POURSUITE MULTI-CIBLES ET CLASSIFICATION DE MOUVEMENTS

4.1. Introduction

La discipline de la poursuite de cibles occupe une grande place dans la littérature, incorporant l'estimation d'état, les techniques de filtrage, les méthodes d'associations de données. Presque tous les systèmes de poursuite modernes utilisent le filtre de Kalman comme un outil central pour l'estimation d'état. Cependant, si la cible est manœuvrante, le succès du filtre de Kalman peut être limité. Les structures alternatives utilisant plusieurs filtres de Kalman en parallèle ont montré une efficacité certaine dans la résolution de ce genre de problème.

Dans la réalité, très rares sont les situations dans lesquelles les cibles évoluent selon un modèle unique. En effet, durant leur trajet, les cibles changent nécessairement de modèles de mouvement. C'est pourquoi, afin d'assurer une bonne estimation de l'état de ces cibles, il faut connaître le modèle de mouvement des cibles afin d'utiliser les outils de filtrage adéquats. Dans ce but, nous associons en général les outils de filtrage et d'association de données aux méthodes de classification de mouvements [41]. Nous n'omettons pas de signaler qu'ils existent plusieurs méthodes de classification de mouvement parmi lesquelles la méthode des modèles multiples interagissant (IMM) [42]. Dans ce chapitre, nous allons étudier la poursuite multi-cibles et la classification de mouvements. Pour cela, nous commençons par présenter des notions sur les cibles manoeuvrantes et les techniques de détection de manoeuvre puis nous décrivons la méthode des modèles multiples interagissant, par la suite nous donnons l'algorithme de cette méthode à base de filtre de Kalman étendu. Nous présentons un aperçu sur le clutter (fouillis) de terre. Ensuite, nous présentons les résultats de simulation numérique pour la poursuite multi-cibles et la classification de mouvements pour différents scénarios avec et sans la présence de clutter, nous terminons ce chapitre par une conclusion.

4.2. Détecteur de manœuvre

La poursuite de cibles manoeuvrantes est un thème revenant fréquemment dans le domaine militaire. En effet, la majorité des systèmes tactiques nécessitent la poursuite de cibles manoeuvrantes tels que les avions, les bateaux, les missiles ou les sous-marins. De même dans le domaine civil, les systèmes de contrôle et de surveillance aériens nécessitent la mise au point de « traqueurs » performants.

La manœuvre se traduit par une accélération de la cible qui engendre une augmentation des erreurs de prédiction et de filtrage. Si ces erreurs sont trop grandes, le processus de corrélation devient incertain et la probabilité de perdre la cible devient importante. L'utilisation d'un détecteur de manœuvre est indispensable pour minimiser les erreurs d'estimation des paramètres d'état des pistes et par conséquent assurer une bonne qualité de poursuite des cibles en phase de manœuvre.

Un détecteur de manœuvre est en général suivi d'une fonction d'adaptation des paramètres du filtre de poursuite à la manœuvre détectée. Parfois, ces deux fonctions peuvent être confondues en un seul bloc, comme montré dans la figure (4.1).

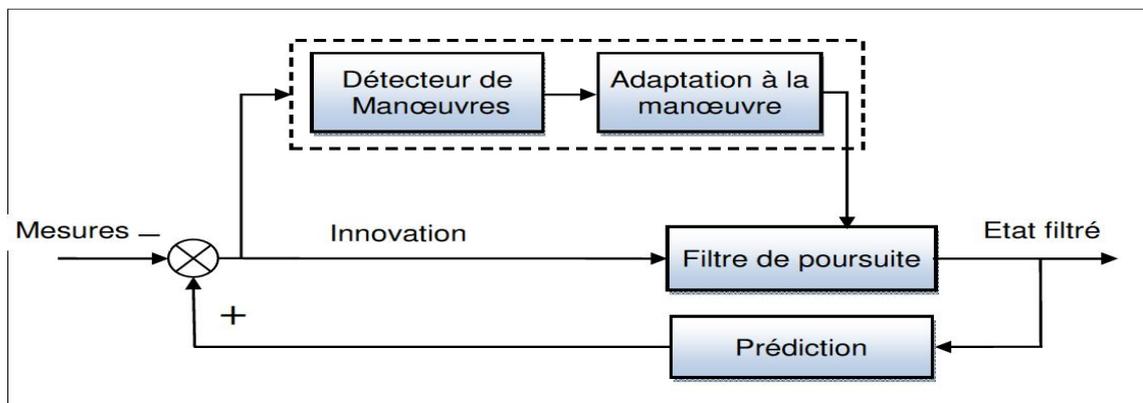


Figure 4.1 : Processus de filtrage en présence d'un détecteur de manœuvre

4.2.1. Techniques de détection de manœuvres

La plupart des techniques de détection de la manœuvre sont basées sur le traitement de l'innovation $z(k)$, donnée par l'équation :

$$z(k+1) = z(k+1) - H \hat{x}(k+1/k) \quad (4.1)$$

C'est une variable aléatoire gaussienne, de moyenne nulle et de matrice de covariance $P(k)$, donnée par :

$$P(k) = HP(k/k-1)H^T + R \quad (4.2)$$

Où x et z sont les vecteurs d'état et de mesure respectivement, H est la matrice d'observation, P est matrice de covariance de l'erreur d'estimation, R est la matrice de covariance du bruit de mesure.

Dès que la valeur de la statistique évaluée dépasse le seuil, on décide de la présence d'une manœuvre. Le seuil est déterminé en fonction de la probabilité de fausse alarme admise, il peut être tiré à partir des références standards des distributions de la statistique correspondante.

En présence d'une manœuvre, un biais s'ajoute à la moyenne de l'innovation qui perd ainsi ses caractéristiques statistiques. Pour déterminer automatiquement le début et la fin d'une manœuvre, plusieurs techniques ont été développées, on peut citer :

- La technique de la fenêtre glissante qui exploite les changements des caractéristiques statistiques de l'innovation en présence de la manœuvre (ajout d'un biais à sa moyenne), pour décider s'il y a une manœuvre ou non. La sommation de l'innovation $\%i$ sur toute la longueur L de la fenêtre est définie par :

$$D_L(k) = \sum_{i=k-L+1}^k \%i \quad \left| \begin{array}{l} \text{oui} \\ > \\ \eta \\ < \\ \text{non} \end{array} \right. \quad (4.3)$$

La statistique $D_L(k)$ est une variable aléatoire gaussienne.

- La technique basée sur le test du signe de l'innovation, où on exploite le signe de l'innovation pendant quelques périodes de balayage du radar, pour affirmer la présence d'une manœuvre. La sommation du signe est définie par :

$$B_{mk}(k) = \sum_{i=0}^{m-1} I(k-1) \quad \left| \begin{array}{l} \text{oui} \\ > \\ \eta \\ < \\ \text{non} \end{array} \right. \quad (4.4)$$

Avec m la longueur de la fenêtre utilisée et la statistique est une variable aléatoire de distribution binomiale.

- La technique basée sur le test de l'erreur quadratique normalisée, elle est donnée par :

$$\rho(k) = \mathbf{z}^T(k)P^{-1}(k)\mathbf{z}(k) \begin{cases} \text{oui} \\ > \eta \sum_{i=0}^{m-1} I(k-i) \\ < \\ \text{non} \end{cases} \quad (4.5)$$

Avec $\rho(k)$ est une variable aléatoire, de loi de probabilité Chi-Deux avec n_z (dimension du vecteur mesure) degrés de liberté.

Ces techniques de détection de manœuvre sont très limitées, elles engendrent des retards de détection qui peuvent causer la perte de la cible. Elles sont faciles à implémenter, mais elles nécessitent souvent une fonction d'adaptation des paramètres du filtre pour former un détecteur efficace [43].

4.2.2. Techniques basées sur l'estimation de l'accélération

Lors de l'utilisation d'un filtre de poursuite, la séquence de l'innovation contient en plus de la composante habituelle du bruit dû aux erreurs de filtrage, la composante déterministe de l'accélération qui est l'erreur du système. Dans le but de réduire cette dernière, l'estimation de l'accélération s'avère nécessaire. Certains algorithmes utilisent un test d'hypothèses pour évaluer l'accélération γ . Si on considère le retard de détection, l'évaluation de γ et de t_0 est obtenue par la résolution d'un problème combiné de l'estimation et de la détection. Cette méthode nécessite l'utilisation d'un banc de filtres (excités par l'innovation) dont chacun est paramétré par un couple (γ, t_0) pour le rendre adapté à un type de manœuvre. Le filtre qui présente la sortie la plus importante nous permet de tirer les caractéristiques correspondantes de la manœuvre (γ, t_0) qui sont utilisées pour la correction du vecteur d'état. L'inconvénient majeur de cette méthode est qu'elle nécessite l'évaluation des sorties de tous les filtres du banc utilisé, ce qui implique un temps de calcul énorme.

Il existe aussi une méthode de l'estimation de l'accélération basée sur le critère de minimisation quadratique de l'innovation, l'estimation s'effectue sans tenir compte des valeurs précédentes de l'accélération ce qui nécessite un large temps de calcul, en plus de la nécessité de ressources mémoires pour le stockage de quelques paramètres.

Une méthode d'estimation basée sur la minimisation de la covariance de l'estimation, qui permet l'estimation de l'accélération à chaque instant, qui est ensuite utilisée pour corriger l'état prédit et filtré. Cette méthode assure de bonnes performances lors de la poursuite des cibles manoeuvrantes, et présente l'avantage de la facilité d'implémentation vu son caractère récursif.

Ces méthodes de détection de manoeuvre basées sur l'estimation de l'accélération permettent en plus de la détection, une adaptation du filtre pour diminuer les erreurs du système causé par la manoeuvre. Par ailleurs, lors du choix d'une méthode, on doit tenir compte surtout de son temps de calcul et de sa complexité d'implémentation [43].

4.3. Modèle Multiple Interagissant (IMM)

L'estimateur (IMM) modèle multiple interagissant [44] en anglais Interacting Multiple Model est une méthodologie qui réalise l'exécution comparable à l'estimateur Pseudo-Bayésien généralisé de deuxième ordre (GPB-2) [45] à l'aide seulement de M filtres élémentaires, plutôt que M^2 selon les exigences du dernier. L'algorithme peut être obtenu en considérant les limitations inhérentes au problème: si seulement M filtres élémentaires sont permis, alors l'entrée au $j^{\text{ième}}$ filtre devrait être la meilleure estimation de l'état à l'instant $k-1$, conditionnée sur l'événement que le modèle j est en vigueur à l'instant k (Le nouvel instant d'échantillonnage) $f\{\underline{x}(k-1) | M_{k,j}, \underline{Z}^{k-1}\}$.

En utilisant cette expression comme point de départ, nous suivons une itération simple de l'algorithme, à travers le calcul de la même fonction à la période d'échantillonnage suivante.

Après un cycle de mise à jour de propagation du filtre de Kalman standard au $k^{\text{ième}}$ instant d'échantillonnage, la sortie de $i^{\text{ième}}$ filtre élémentaire sera $f\{\underline{x}(k) | M_{k,i}, \underline{Z}^k\}$. La condition pour l'algorithme IMM est donc de combiner les estimations des M filtres élémentaires pour calculer les entrées $f\{\underline{x}(k) | M_{k+1,j}, \underline{Z}^k\}$ de chaque filtre élémentaire pour le prochain cycle de traitement.

La PDF globale formée en utilisant l'information de tous les M filtres représente l'information totale contenue par le système à l'instant k :

$$f\{\underline{x}(k) | \underline{Z}^k\} = \sum_{j=1}^M f\{\underline{x}(k) | M_{k,j}, \underline{Z}^k\} P\{M_{k,j} | \underline{Z}^k\} \quad (4.6)$$

Où la notation $P\{.\}$ se rapporte à la probabilité d'un événement discret, tandis que $f\{.\}$ se rapporte à la fonction de densité de probabilité d'une variable continue. Le but de l'entremêlement est ainsi de masser l'équation (4.6) dans l'expansion nécessaire à l'entrée du prochain cycle de traitement:

$$f\{\underline{x}(k) | \underline{Z}^k\} = \sum_{i=1}^M f\{\underline{x}(k) | M_{k+1,i}, \underline{Z}^k\} P\{M_{k+1,i} | \underline{Z}^k\} \quad (4.7)$$

Le dernier facteur dans l'équation (4.7) est facilement évalué :

$$P\{M_{k+1,i} | \underline{Z}^k\} = \sum_{j=1}^M P\{M_{k+1,i} | M_{k,j}\} P\{M_{k,j} | \underline{Z}^k\} \quad (4.8)$$

Noter que si $T(k+1|k)$ est la matrice de transitions de Markov telle que:

$$\{T\}_{ij} = P\{M_{k+1,i} | M_{k,j}\} \quad (4.9)$$

Alors l'équation (4.8) est simplement une multiplication de la matrice $T(k+1|k)$ par le vecteur avec des éléments qui sont les probabilités $P\{M_{k,j} | \underline{Z}^k\}$, rapportant le vecteur des composants qui représentent les probabilités $P\{M_{k+1,i} | \underline{Z}^k\}$.

Le facteur principal dans la somme de l'équation (4.7) est alors augmenté en utilisant le théorème de probabilité totale au-dessus du modèle précédent de l'index j :

$$f\{\underline{x}(k) | M_{k+1,i}, \underline{Z}^k\} = \sum_{j=1}^M f\{\underline{x}(k) | M_{k+1,i}, M_{k,j}, \underline{Z}^k\} P\{M_{k,j} | M_{k+1,i}, \underline{Z}^k\} \quad (4.10)$$

Où les probabilités en arrière de transition sont calculées par :

$$\begin{aligned}
P\{M_{k,j} | M_{k+1,i}, \underline{Z}^k\} &= \frac{P\{M_{k,j}, M_{k+1,i} | \underline{Z}^k\}}{P\{M_{k+1,i} | \underline{Z}^k\}} \\
&= \frac{P\{M_{k+1,i} | M_{k,j}, \underline{Z}^k\} P\{M_{k,j} | \underline{Z}^k\}}{P\{M_{k+1,i} | \underline{Z}^k\}} \\
&= \frac{P\{M_{k+1,i} | M_{k,j}, \underline{Z}^k\} P\{M_{k,j} | \underline{Z}^k\}}{\sum_{n=1}^M P\{M_{k+1,i} | M_{k,n}, \underline{Z}^k\} P\{M_{k,n} | \underline{Z}^k\}}
\end{aligned} \tag{4.11}$$

Selon l'hypothèse de Markov, la probabilité de transition $P\{M_{k+1,i} | M_{k,j}, \underline{Z}^k\}$ ne dépend pas de l'histoire de mesure \underline{Z}^k .

Supposant que l'histoire \underline{Z}^k de l'estimateur est convenablement modélisée par les M estimations du cycle de traitement précédent (chaque estimation conditionnée sur un modèle différent $M_{k,j}$), l'équation (4.10) est alors approximée par une densité gaussienne simple :

$$\begin{aligned}
f\{\underline{x}(k) | M_{k+1,i}, \underline{Z}^k\} &\approx \sum_{j=1}^M f\{\underline{x}(k) | M_{k+1,i}, \hat{\underline{x}}_j(k|k), P_j(k|k)\} P\{M_{k,j} | M_{k+1,i}, \underline{Z}^k\} \\
&\approx N\{\underline{x}(k), \hat{\underline{x}}^i(k|k), P^i(k|k)\}
\end{aligned} \tag{4.12}$$

Dont la moyenne et la variance de la gaussienne sont données par :

$$\hat{\underline{x}}^i(k|k) = \sum_{j=1}^M P\{M_{k,j} | M_{k+1,i}, \underline{Z}^k\} \hat{\underline{x}}_j(k|k) \tag{4.13}$$

$$\begin{aligned}
P^i(k|k) &= \sum_{j=1}^M P\{M_{k,j} | M_{k+1,i}, \underline{Z}^k\} \{P_j(k|k) + \\
&\quad [\hat{\underline{x}}_j(k|k) - \hat{\underline{x}}^i(k|k)] [\hat{\underline{x}}_j(k|k) - \hat{\underline{x}}^i(k|k)]^T\}
\end{aligned} \tag{4.14}$$

Avec :

$$\mu_{i,j}(k|k) = P\{M_{k,j} | M_{k+1,i}, \underline{Z}^k\} \tag{4.15}$$

Les probabilités a posteriori des modèles $P\{M_{k,j} | \underline{Z}^k\}$ exigées par l'équation (4.11) sont récursivement calculées en utilisant les expressions :

$$\begin{aligned}
 P\{M_{k,j} | \underline{Z}^k\} &= P\{M_{k,j} | z(k), \underline{Z}^{k-1}\} \\
 &= \frac{f\{M_{k,j}, z(k) | \underline{Z}^{k-1}\}}{f\{z(k) | \underline{Z}^{k-1}\}} \\
 &= \frac{f\{z(k) | M_{k,j}, \underline{Z}^{k-1}\} P\{M_{k,j} | \underline{Z}^{k-1}\}}{f\{z(k) | \underline{Z}^{k-1}\}}
 \end{aligned} \tag{4.16}$$

Comme discuté dans l'équation (4.8), $P\{M_{k,j} | \underline{Z}^{k-1}\}$ peut être augmentée ou développée en utilisant le théorème de probabilité totale comme :

$$\begin{aligned}
 P\{M_{k,j} | \underline{Z}^{k-1}\} &= \sum_{j=1}^M P\{M_{k,j} | M_{k-1,i}, \underline{Z}^{k-1}\} P\{M_{k-1,i} | \underline{Z}^{k-1}\} \\
 P\{M_{k,j} | \underline{Z}^{k-1}\} &= \sum_{j=1}^M P\{M_{k,j} | M_{k-1,i}\} P\{M_{k-1,i} | \underline{Z}^{k-1}\}
 \end{aligned} \tag{4.17}$$

Ou l'hypothèse que la probabilité de transition du modèle ne dépend pas de l'histoire de mesure est de nouveau appelée.

Ainsi, la substitution dans l'équation (4.17) et en augmentant le dénominateur en utilisant le théorème de probabilité totale, on aura :

$$P\{M_{k,j} | \underline{Z}^k\} = \frac{f\{z(k) | M_{k,j}, \underline{Z}^{k-1}\} \sum_{j=1}^M P\{M_{k,j} | M_{k-1,i}\} P\{M_{k-1,i} | \underline{Z}^{k-1}\}}{\sum_{n=1}^M f\{z(k) | M_{k,n}, \underline{Z}^{k-1}\} P\{M_{k,n} | \underline{Z}^{k-1}\}} \tag{4.18}$$

(Notez que le dénominateur est simplement le facteur de normalisation nécessaire pour assurer que la somme de probabilités des modèles conditionnels est égale à 1).

Selon les techniques des modèles multiples précédentes, l'estimation combinée est calculée à chaque cycle de traitement pour donner la sortie de l'estimateur. Un fonctionnel de l'algorithme IMM est montré dans la figure (4.2). La structure est très semblable à la structure des modèles fixes (cas de non changement de modèles): il y a M filtres, dont chacun est fourni avec une entrée différente. Cependant, plutôt que de passer la sortie de chaque filtre directement dans le même filtre au prochain cycle de traitement, l'algorithme mélange les estimations selon le modèle de transition de Markov afin de permettre au système de réagir aux changements au modèle en vigueur. D'une autre façon, l'entrée au filtre assorti du modèle i est obtenue par une interaction de M filtres, qui consiste à mélanger les estimés $\hat{x}_j(k|k)$ avec les pondérations (probabilités de classification) $\mu_j(k|k)$ appelées probabilités mixtes dans le but d'obtenir l'état estimé global et sa matrice de covariance [44].

La structure de l'algorithme est :

$$(N_e ; N_f) = (M ; M) \quad (4.19)$$

Où N_e est le nombre d'estimations au début du cycle de traitement et N_f est le nombre de filtres dans l'algorithme.

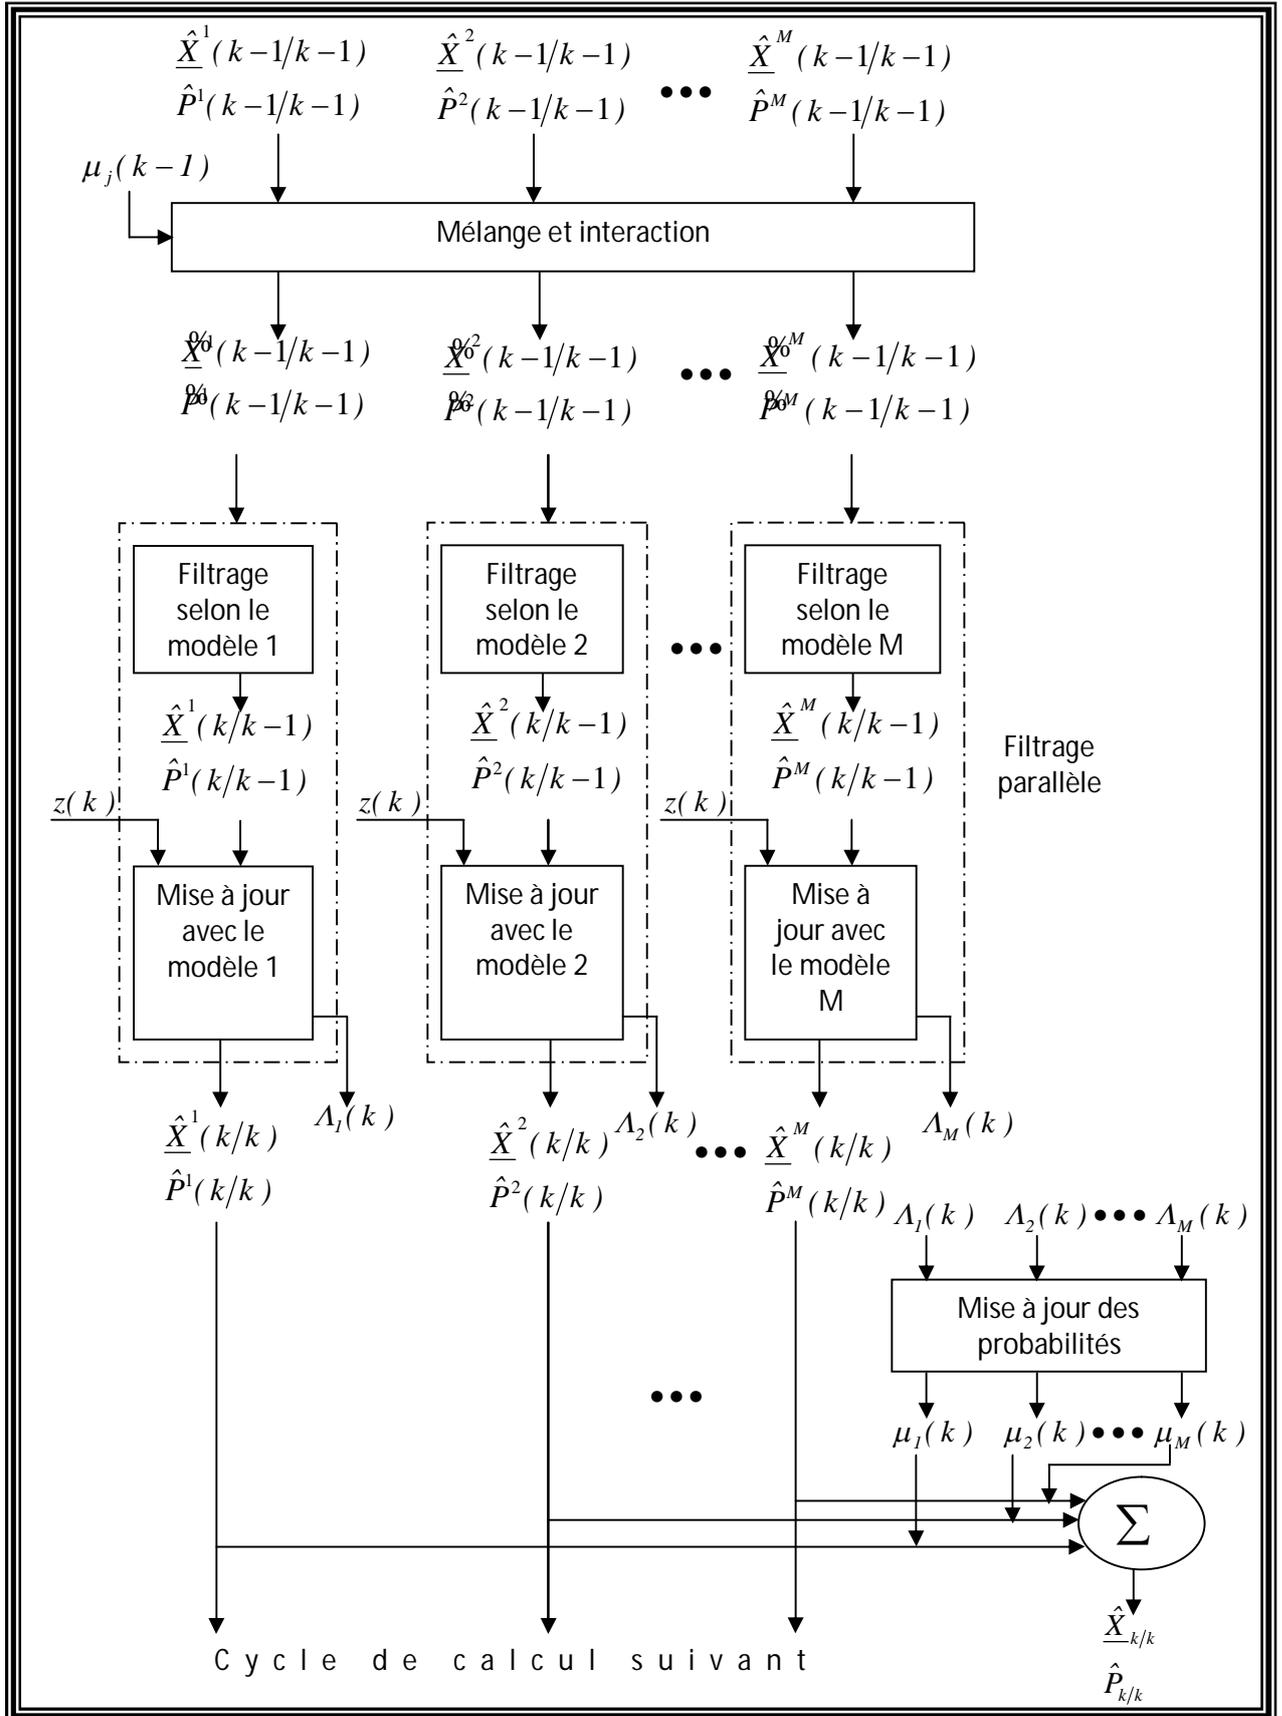


Figure 4.2 : Schéma descriptif de l'algorithme IMM

4.4. Modèle multiples interagissant à base de filtre de Kalman étendu (IMM-EKF)

Le problème de la poursuite de cibles manoeuvrantes a été étudié dans le champ de l'estimation d'état. Le filtre de Kalman a été largement utilisé pour estimer l'état de la cible, mais en présence d'une manoeuvre son exécution peut être sérieusement dégradée. Pour résoudre ce problème et poursuivre une cible manoeuvrante efficacement, un algorithme modèle multiple interagissant (IMM) a été proposé par Blom [44], cet algorithme contient plusieurs filtres de Kalman (IMM-EKF) travaillant en parallèle. L'outil de base de cet algorithme est le filtre de kalman, et cela pour des modèles linéaires. Mais, lorsqu'une non linéarité apparaît sur les modèles, il doit les linéariser pour qu'on puisse appliquer le filtre de kalman sur ces modèles, et le filtre souvent utilisé est le filtre de Kalman Etendu (EKF) et l'algorithme devient « Interacting Multiple Model Extended Kalman Filters » (IMM-EKF).

4.4.1. L'algorithme de poursuite IMM-EKF

IMM-EKF est une méthode de filtrage basé sur filtre de Kalman étendu. Dont, à l'instant k , l'état estimé est la combinaison de M estimés calculés selon les M modèles choisis. L'algorithme consiste à mélanger les probabilités des modèles et les états estimés et leurs covariances à la sortie des filtres. Chaque filtre utilise ces estimés mixtes au début de chaque cycle. L'étape de calcul des estimés mixtes, qui sont déterminés par les probabilités de classification (switching) μ_{ij} entre modèles, est la plus importante de l'algorithme IMM. Cet algorithme fonctionne selon les quatre étapes suivantes :

a. Estimation mixte pour le modèle j

Les estimés (entrées) mixtes sont l'initialisation de chaque filtre

- Probabilités des transitions : P_{ij}
- Probabilité du modèle j à l'instant $k-1$: $\mu_j(k-1)$.
- Probabilité prédite du modèle :

$$\bar{\mu}_j = \sum_i P_{ij} \mu_i(k-1) \quad (4.20)$$

- Probabilité mixte du modèle j :

$$\mu_{ij} = \frac{P_{ij}\mu_i(k-1)}{\bar{\mu}_j} \quad (4.21)$$

- Etat estimé mixte du modèle j :

$$\hat{\underline{x}}_{0j}(k-1/k-1) = \sum_i \underline{x}_i(k-1/k-1)\mu_{ij} \quad (4.22)$$

- Covariance estimée mixte du modèle j :

$$P_{0j}(k-1/k-1) = \sum_i \mu_{ij} \{P_i(k-1/k-1) + V_{ij}\} \quad (4.23)$$

$$V_{ij} = [\hat{\underline{x}}_i(k-1/k-1) - \hat{\underline{x}}_{0j}(k-1/k-1)][\hat{\underline{x}}_i(k-1/k-1) - \hat{\underline{x}}_{0j}(k-1/k-1)]^T \quad (4.24)$$

b. Filtrages parallèles

- ❖ Prédiction :

- Prédiction d'état :

$$\hat{\underline{x}}_j(k/k-1) = F(\hat{\underline{x}}_{0j}(k-1/k-1), k-1) \quad (4.25)$$

- Prédiction de covariance :

$$P_j(k/k-1) = F(\hat{\underline{x}}_{k/k-1}, k)P_{0j}(k-1/k-1)F^T(\hat{\underline{x}}_{k/k-1}, k) + Q(k/k-1) \quad (4.26)$$

- ❖ Correction :

- L'innovation :

$$\begin{aligned} \gamma_j(k) &= z(k) - \hat{z}_j(k/k-1) \\ \hat{z}_j(k/k-1) &= h(\underline{x}_j(k/k-1)) \end{aligned} \quad (4.27)$$

- Covariance de l'innovation :

$$S_j(k) = H(\underline{x}_{k/k-1}, k-1)P_j(k/k-1)H^T(\underline{x}_{k/k-1}, k-1) + R(k/k-1) \quad (4.28)$$

➤ Gain du filtre :

$$K_j(k) = P_j(k/k-1)H^T(\hat{\underline{x}}_{k/k-1}, k-1)S_j^{-1}(k) \quad (4.29)$$

➤ Etat estimé :

$$\hat{\underline{x}}_j(k/k) = \hat{\underline{x}}_j(k/k-1) + K_j(k)\gamma(k/k-1) \quad (4.30)$$

➤ Covariance estimée :

$$P_j(k/k) = P_j(k/k-1) - K_j(k)S_j(k)K_j^T(k) \quad (4.31)$$

c. Mise à jour de probabilités du modèle j

➤ Fonction de vraisemblance du modèle j

$$\Lambda_j(k) = (2\pi)^{-1} |S_j(k)|^{-\frac{1}{2}} \exp(-0.5\gamma_j^T(k)S_j^{-1}(k)\gamma_j(k)) \quad (4.32)$$

➤ Mise à jour de probabilité du modèle j :

$$\mu_j(k) = \frac{\bar{\mu}_j \Lambda_j}{\sum_i \bar{\mu}_i \Lambda_i} \quad (4.33)$$

d. Estimation combinée :

➤ Etat estimé combiné :

$$\hat{\underline{x}}(k/k) = \sum_j \hat{\underline{x}}_j(k/k)\mu_j(k) \quad (4.34)$$

➤ Covariance estimée combinée :

$$P(k/k) = \sum_j \mu_j(k) \left\{ P_j(k/k) + \left[\hat{\underline{x}}(k/k) - \hat{\underline{x}}_j(k/k) \right] \left[\hat{\underline{x}}(k/k) - \hat{\underline{x}}_j(k/k) \right]^T \right\} \quad (4.35)$$

4.5. Modélisation du clutter (fouillis) de terre

Depuis un certain nombre de décennies, le fouillis dû au retour de la surface de la terre ou de la mer a été modélisé par un processus stochastique. Pour les radars à basse résolution, l'amplitude du fouillis est distribuée selon Rayleigh. Tandis que pour les radars à haute résolution, le fouillis devient impulsif, d'où le caractère non gaussien.

La majeure partie de la recherche sur le fouillis non gaussien consiste à trouver une distribution appropriée qui permet d'approcher les données expérimentales. Par exemple, il a été observé expérimentalement que dans beaucoup de cas, les distributions Weibull, log normal, ou la distribution K, sont de meilleures approximations pour des statistiques d'amplitude du fouillis qu'une distribution de Rayleigh. Il est à préciser que jusqu'à présent on n'a proposé aucun modèle simple pour le fouillis.

Dans ce chapitre on va utiliser un clutter (fouillis) de terre de distribution log normal (voir appendice C), on le présente brièvement dans ce paragraphe.

- Clutter de terre :

Le clutter de terre est plus difficile à quantifier et à classifier que le clutter de mer. La densité de probabilité lognormal (voir Appendice C) a été suggérée par Schleher [46] et Goldstein [47] pour modéliser ce type de clutter. Il est montré que ce modèle est plus proche des données réelles. La densité de probabilité est exprimée comme suit :

$$f_x(x) = \frac{1}{x\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{\ln x - \mu}{\sigma}\right)^2\right] \sigma \geq 0 \quad (4.36)$$

μ est la moyenne de $\ln x$ représente le paramètre d'échelle et σ est l'écart type de $\ln x$ est connu sous le nom de paramètre de forme [48].

4.6. Simulation numérique

- Modèles de mouvements

En ce qui concerne les modèles susceptibles de décrire les mouvements possibles d'une cible, nous utilisons dans la suite de ce travail les modèles suivants :

- Modèle **M1** Mouvement rectiligne à vitesse constante (voir paragraphe 2.6).
- Modèle **M2** Mouvement circulaire à vitesse de rotation constante (voir paragraphe 3.6).
- Modèle **M3** Mouvement rectiligne à accélération constante :

Dans ce modèle de mouvement, les accélérations de la cible sont inconnues. Pour cela, il est important d'augmenter la taille du vecteur d'état donné par (2.31), qui devient alors :

$$\underline{X}_k = [x_k, \dot{x}_k, \ddot{x}_k, y_k, \dot{y}_k, \ddot{y}_k]^T \quad (4.37)$$

Dans ce modèle, la fonction $f_3(\cdot)$ et la matrice de commande sont données par [26] :

$$f_3(\underline{X}_k) = \text{diag} \left\{ \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}, \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix} \right\} \underline{X}_k \quad (4.38)$$

$$G_3 = \text{diag} \left\{ \begin{bmatrix} T^2/2 \\ T \\ 1 \end{bmatrix}, \begin{bmatrix} T^2/2 \\ T \\ 1 \end{bmatrix} \right\} \quad (4.39)$$

- Dans ce chapitre on va travailler avec des cibles qui changent leurs modèles de mouvements pour cela dans les paragraphes précédents nous avons vu des notions sur les modèles multiples interagissant à base de filtre de Kalman étendu. Dans la figure (4.3) nous présentons l'algorithme, que nous allons utiliser pour répondre aux objectifs de la poursuite multi-cibles et de la classification de mouvement, cet algorithme est basée sur l'association des (JPDA, NN, CD) à l'IMM-EKF, donc ((JPDA, NN, CD)-IMM-EKF).

- *Initialisation* : pour chaque cible tr ($tr = 1, \dots, N_{CIB}$) et pour chaque modèle j ($j = 1, \dots, M$)
 - choisir l'état initial $\hat{\underline{X}}_{tr,0}^j$
 - initialiser la matrice de covariance $P_{tr,0}^j$ et la probabilité du modèle $\mu_{tr,0}^j = 1/M$.

- *Etape de mixage* : étape d'interaction et mixage des modèles

- calcul (pour $i, j = 1, \dots, M$), la probabilité mixte

$$\mu_{tr,k-1/k-1}^{i|j} = \frac{1}{\bar{c}_{tr}^j} p_{ij} \mu_{tr,k-1}^i \quad \text{avec} \quad \bar{c}_{tr}^j = \sum_{i=1}^M p_{ij} \mu_{tr,k-1}^i$$

- calcul pour chaque modèle j , les états mixtes et les matrices de covariances mixtes

- l'état mixte $\underline{\hat{X}}_{tr,k-1/k-1}^j = \sum_{i=1}^M \mu_{tr,k-1/k-1}^{i|j} \hat{\underline{X}}_{tr,k-1/k-1}^i$

- la matrice de covariance mixte

$$\underline{P}_{tr,k-1/k-1}^j = \sum_{i=1}^M \mu_{tr,k-1/k-1}^{i|j} \left\{ \hat{P}_{tr,k-1/k-1}^i + \varepsilon_{tr,k-1}^{ij} \varepsilon_{tr,k-1}^{ijT} \right\}, \quad \text{avec} \quad \varepsilon_{tr,k-1}^{ij} = \hat{\underline{X}}_{tr,k-1/k-1}^i - \underline{\hat{X}}_{tr,k-1/k-1}^j$$

- *Filtrage parallèle* : application de l'EKF pour chaque modèle j en utilisant l'état mixte et la $\underline{\hat{X}}_{tr,k-1/k-1}^j$ matrice de covariance $\underline{P}_{tr,k-1/k-1}^j$ comme des entrées.

- prédiction
- association de données par l'une des méthodes JPDA ou NN ou CD
- mise à jours de l'état et de la matrice de covariance : $\hat{\underline{X}}_{tr,k/k}^j$ et $\hat{P}_{tr,k/k}^j$
- obtenir la vraisemblance $\Lambda_{tr,k}^j = N(\underline{Z}_k | j, \underline{\hat{X}}_{tr,k-1/k-1}^j, \underline{P}_{tr,k-1/k-1}^j)$ (N : la loi normal)
 - après l'association par JPDA

$$\Lambda_{tr,k}^j = (2\pi)^{-1} |S_j(k)|^{-\frac{1}{2}} \exp\left(-0.5 \text{Inov}_{tr}^{jT}(k) S_j^{-1}(k) \text{Inov}_{tr}^j(k)\right)$$

$$\text{où} \quad \begin{cases} \text{Inov}_{tr}^j(k) = \sum_{z=1}^{m(k)} \beta_{tr,z}^j(k) \text{Inov}_{tr,z}^j(k) \\ \text{Inov}_{tr,z}^j(k) = \underline{Z}_z(k) - h\left(\hat{\underline{X}}_{tr,k/k-1}^j\right) \end{cases}$$

- après l'association par NN

$$\Lambda_{tr,k}^j = (2\pi)^{-1} |S_{tr,j}(k)|^{-\frac{1}{2}} \exp\left(-0.5 \left(\underline{Z}_k^{NN} - \underline{Z}_{tr,pk}^j\right)^T S_j^{-1}(k) \left(\underline{Z}_k^{NN} - \underline{Z}_{tr,pk}^j\right)\right)$$

- après l'association par CD

$$\Lambda_{tr,k}^j = (2\pi)^{-1} |S_{tr,j}(k)|^{-\frac{1}{2}} \exp\left(-0.5 \left(\underline{Z}_k^{CD} - \underline{Z}_{tr,pk}^j\right)^T S_j^{-1}(k) \left(\underline{Z}_k^{CD} - \underline{Z}_{tr,pk}^j\right)\right)$$

- *Mise à jour des probabilités des modèles* : calcul de la probabilité de classification du modèle j :

$$\mu_{tr,k}^j = \frac{1}{c_{tr}} \Lambda_{tr,k}^j \bar{c}_{tr}^j \quad \text{avec} \quad c_{tr} = \sum_{i=1}^M \Lambda_{tr,k}^i \bar{c}_{tr}^i$$

- *Estimation combinée*

- l'état estimé combiné $\hat{\underline{X}}_{tr,k/k} = \sum_{i=1}^M \mu_{tr,k}^i \hat{\underline{X}}_{tr,k/k}^i$

- la matrice de covariance combinée

$$P_{tr,k} = \sum_{i=1}^M \mu_{tr,k}^i \left\{ P_{tr,k/k}^i + \varepsilon_{tr,k}^i \varepsilon_{tr,k}^{iT} \right\} \quad \text{avec} \quad \varepsilon_{tr,k}^i = \hat{\underline{X}}_{tr,k/k} - \hat{\underline{X}}_{tr,k/k}^i$$

Figure 4.3 : L'algorithme (JPDAF, NN, CD)-IMM-EKF

- Afin de comparer les performances de la poursuite et de la classification de mouvements des cibles en utilisant les NN, les JPDA et CD, nous considérons deux scénarios possibles :
 - Scénario Sc3 : Trois cibles parallèles qui changent leurs modèles de mouvement pendant leur trajet.
 - Scénario Sc4 : Trois cibles se croisent qui changent leurs modèles de mouvement pendant leur trajet.

Scénario **Sc3** : Dans le but de tester la robustesse des méthodes d'association de données vis-à-vis du risque de confusion permanent durant tout le trajet, nous considérons le cas de trois cibles parallèles en mouvement selon le modèle M1 pendant 88 T puis selon le modèle M2 pendant 82 T avec une vitesse de rotation égale à -0.018rd/s enfin selon le modèle M3 pendant 30 T avec une accélération égale à 0.8m/s^2 identique sur les deux axes. La distance réelle entre deux cibles est toujours égale à 50m.

Scénario **Sc4** : Afin de tester la robustesse des méthodes d'association de données vis-à-vis du risque de confusion lors du croisement, nous considérons trois cibles en mouvement selon le modèle M1 pendant 88 T, puis le modèle M2 pendant 87 T avec une vitesse de rotation de 0.014rd/s et enfin le modèle M3 pendant 25 T avec une accélération de 1m/s^2 identique sur les deux axes. Les cibles se croisent à l'instant 50 T.

- Pour étudier les performances, nous allons effectuer 100 réalisations indépendantes de Monte-Carlo (voir Appendice B) [40], afin d'évaluer les performances suivantes :
 - L'erreur quadratique moyenne en position REQMP.
 - L'erreur quadratique moyenne en vitesse REQMV.
 - Probabilités d'association.
 - Probabilités de classification de mouvement.
- Afin de comparer ces performances, nous allons considérer différentes situations :
 - Situation **S3** : poursuite et classification de mouvement sans la présence de clutter.
 - Situation **S4** : poursuite et classification de mouvement avec la présence de clutter de terre (voir appendice C).

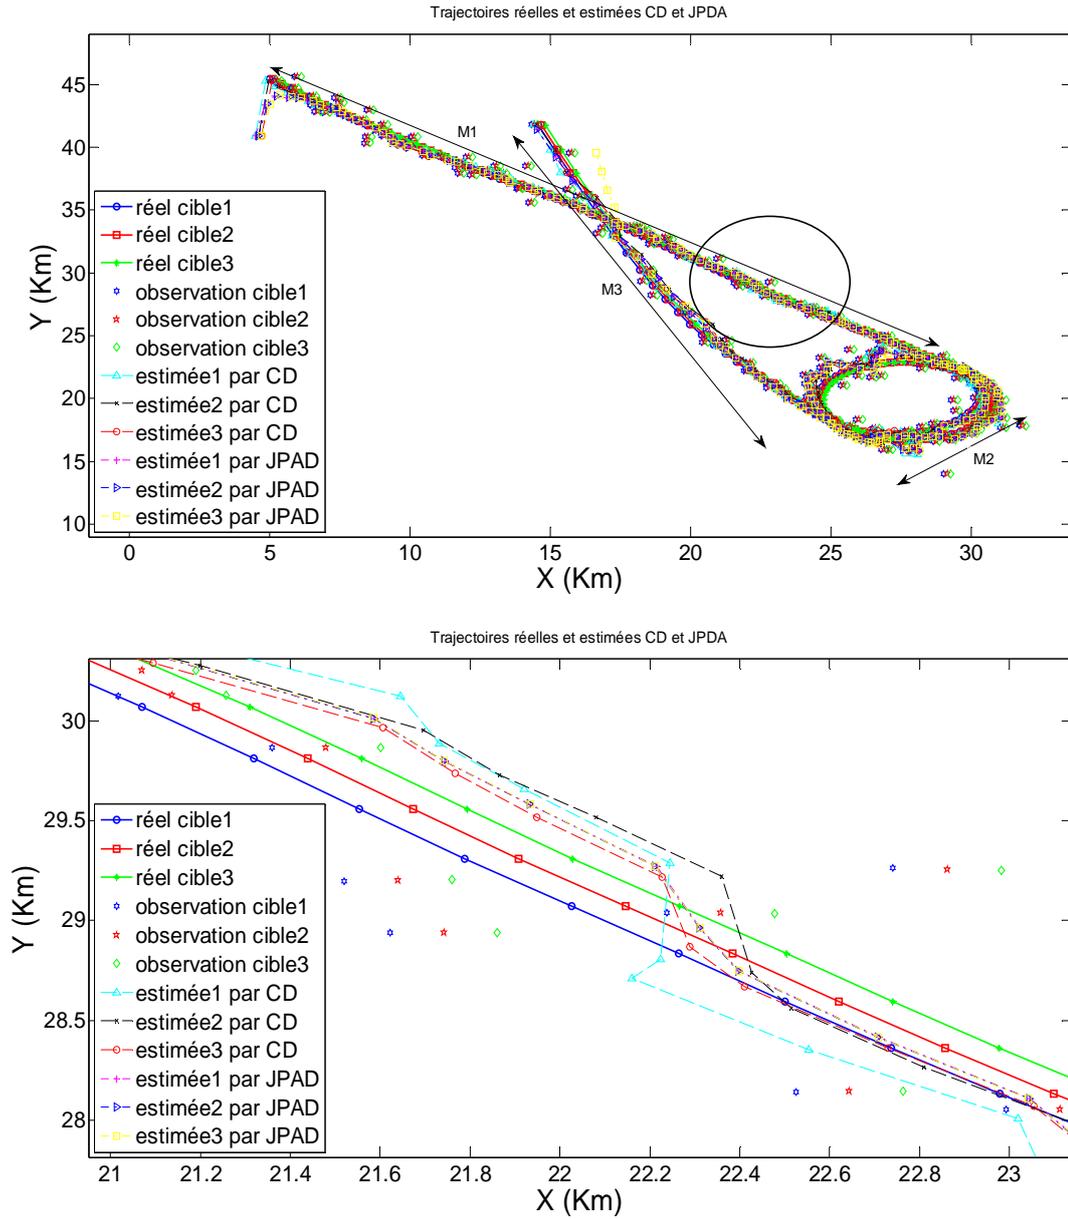


Figure 4.4 : Trajectoires réelles et estimées par CD et JPDA pour (S3, Sc3)

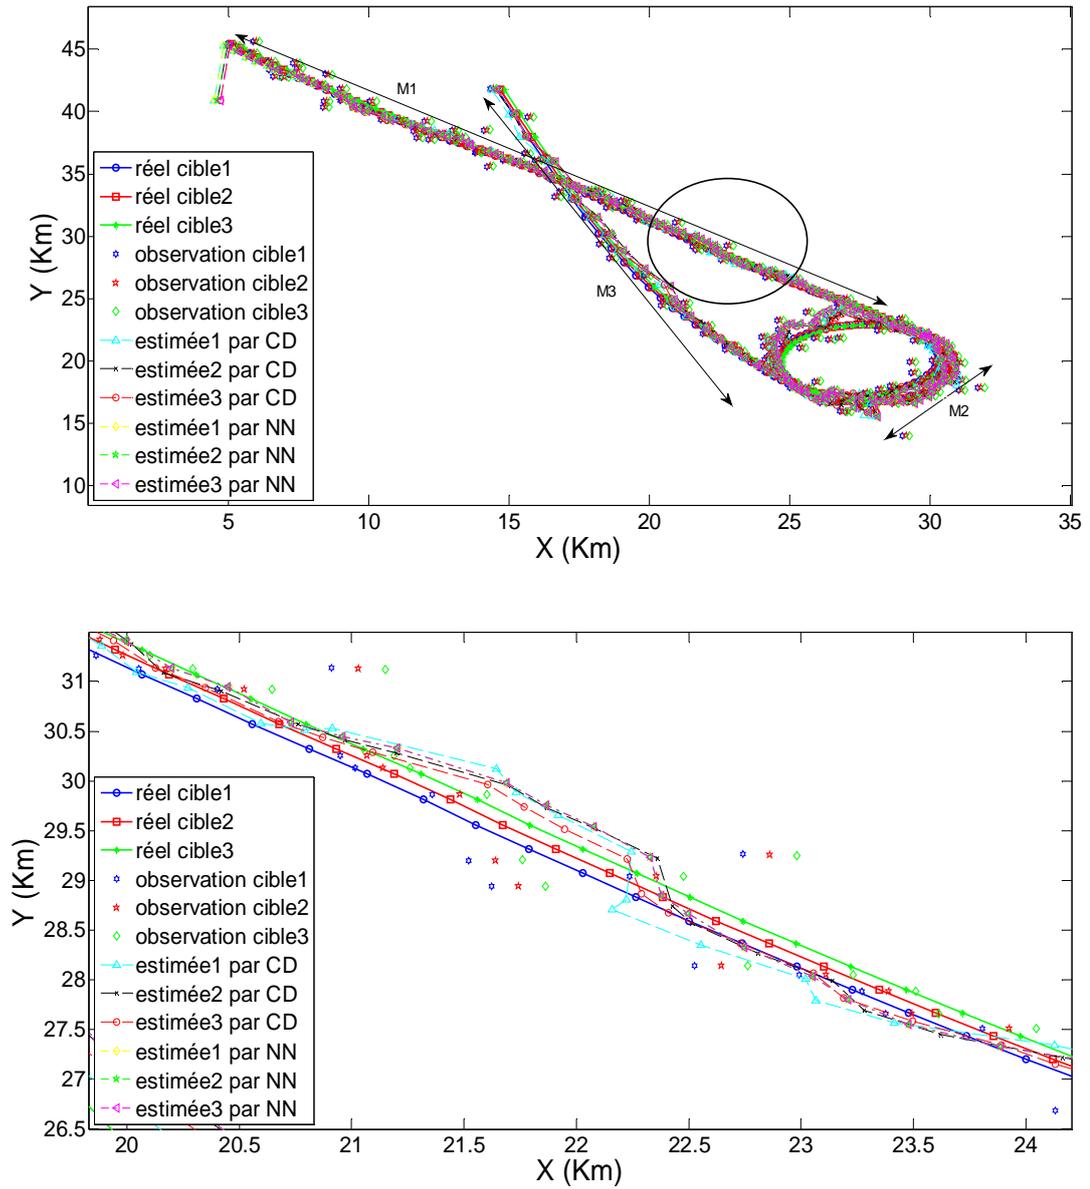


Figure 4.5 : Trajectoires réelles et estimées par CD et NN pour (S3, Sc3)

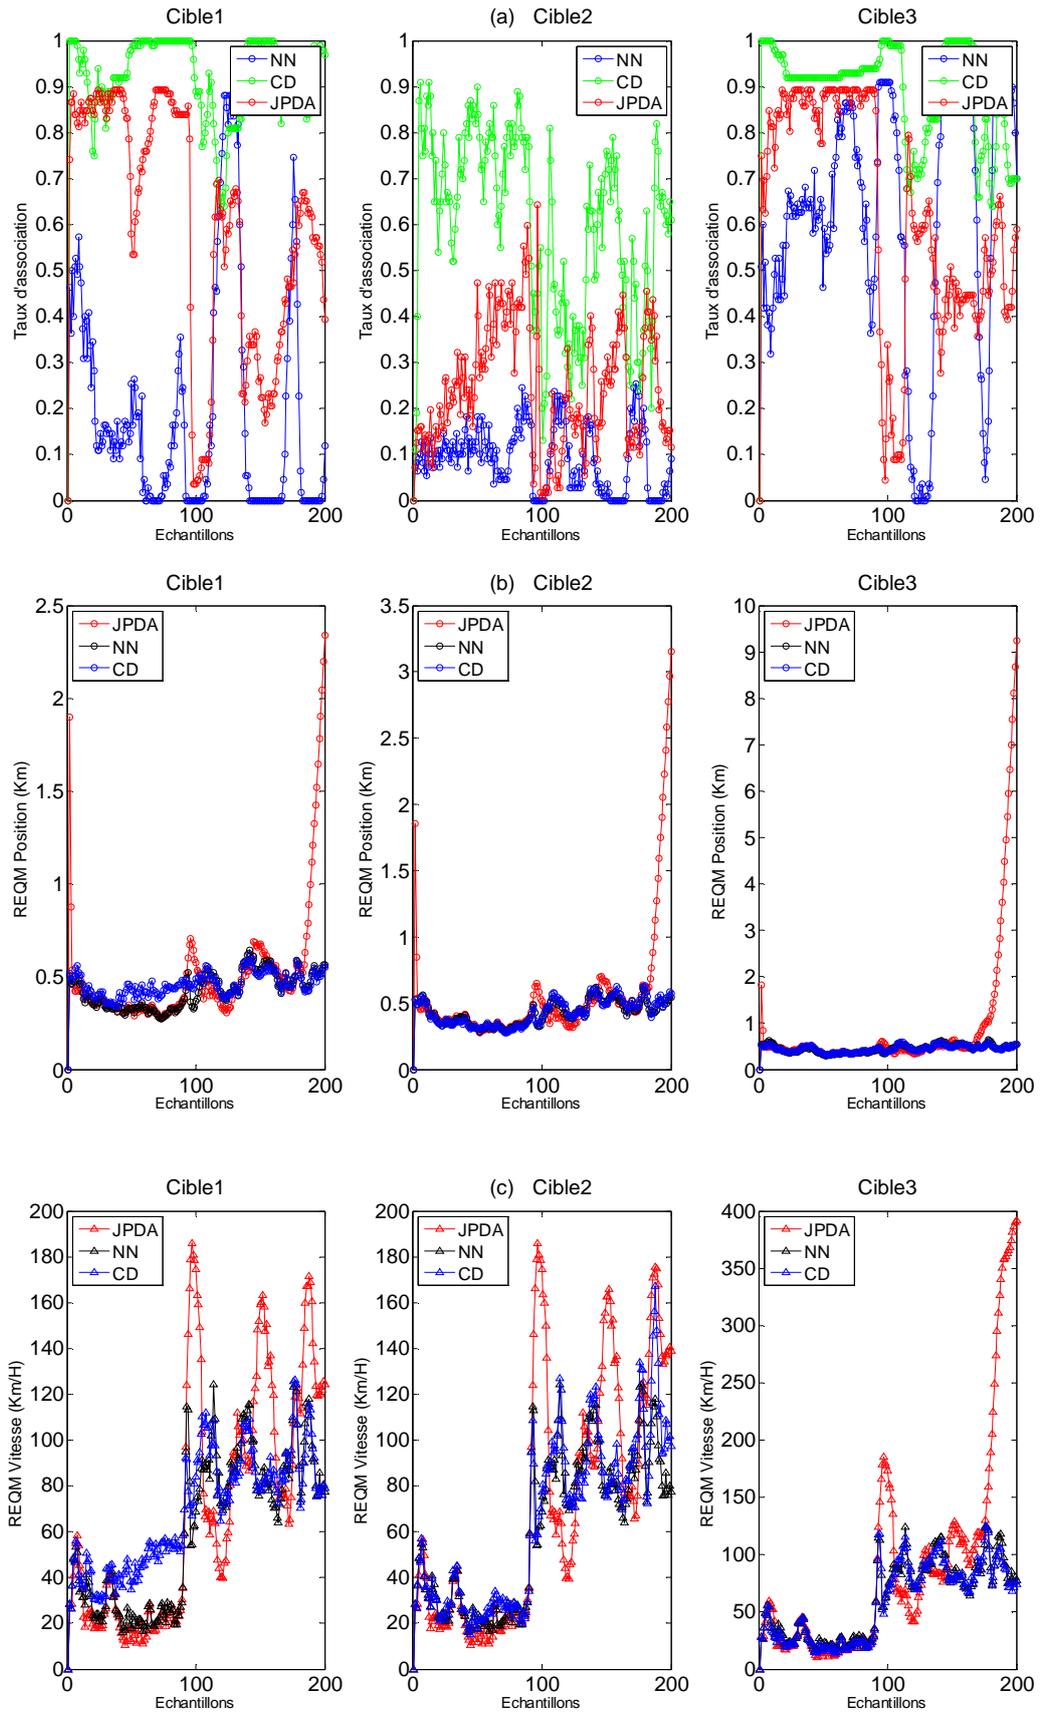


Figure 4.6 : Les mesures de performances CD, NN et JPDA pour (S3, Sc3)
 (a) taux d'association (b) REQM P (c) REQM V

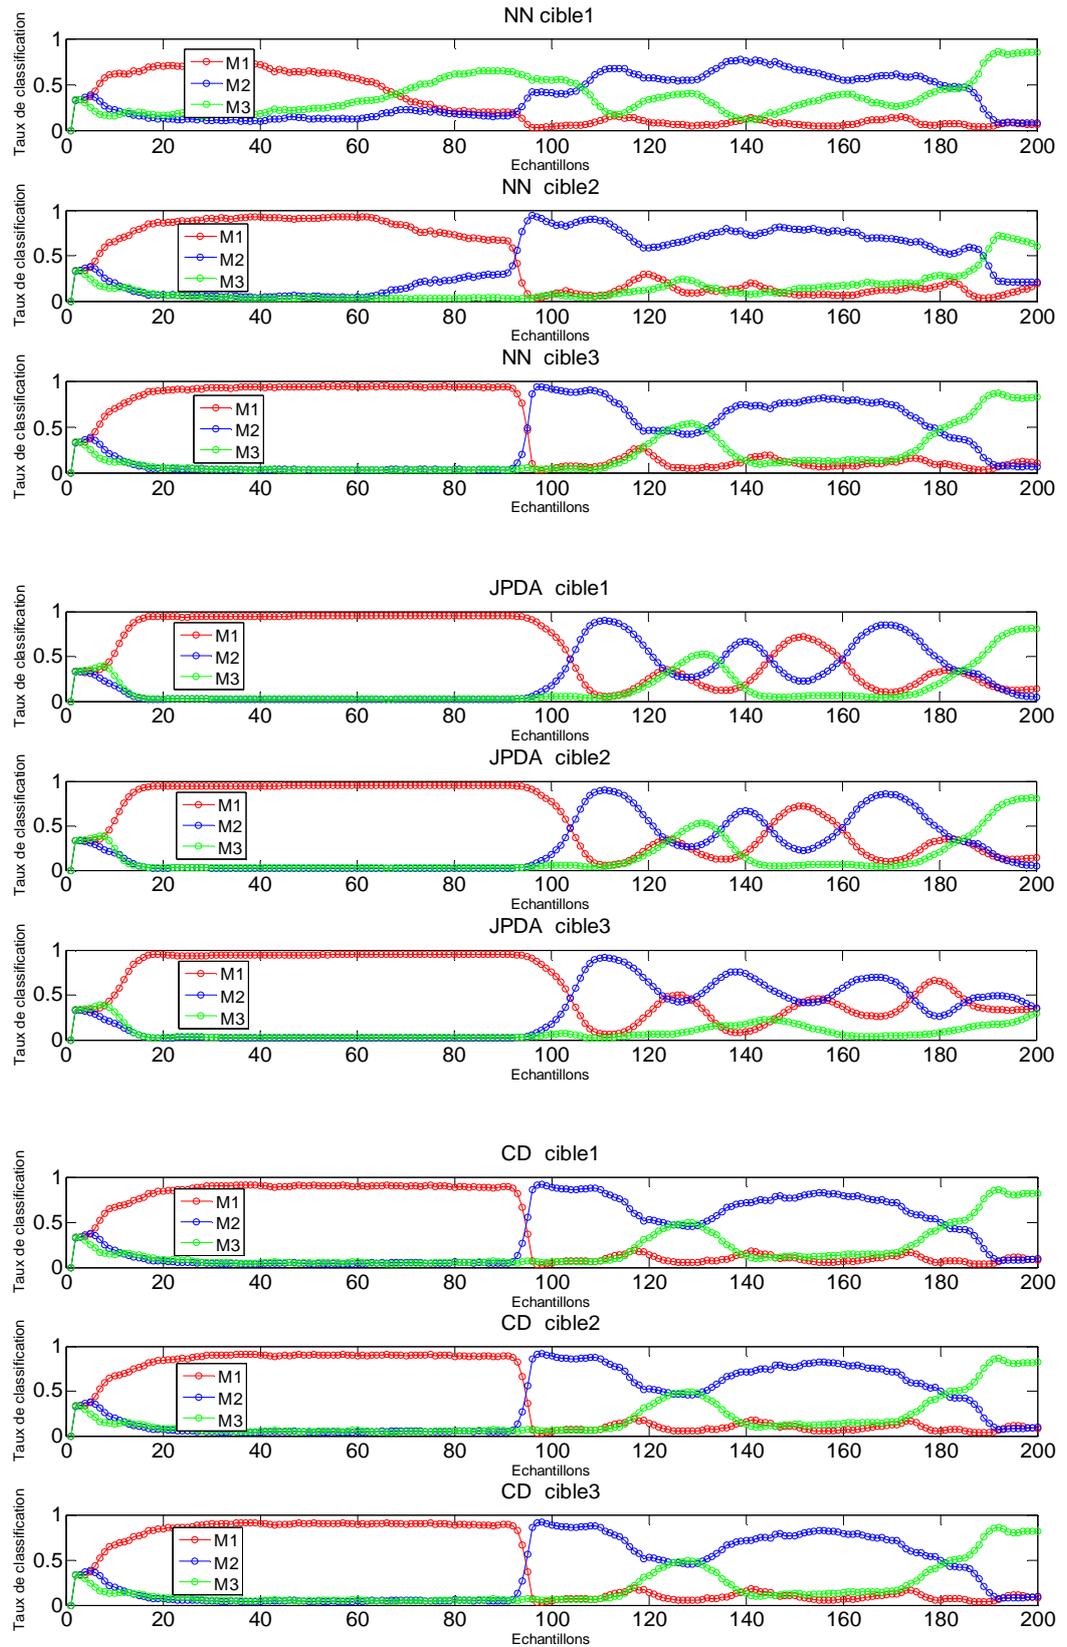


Figure 4.7 : la probabilité de classification cible de mouvement pour (S3, Sc3)

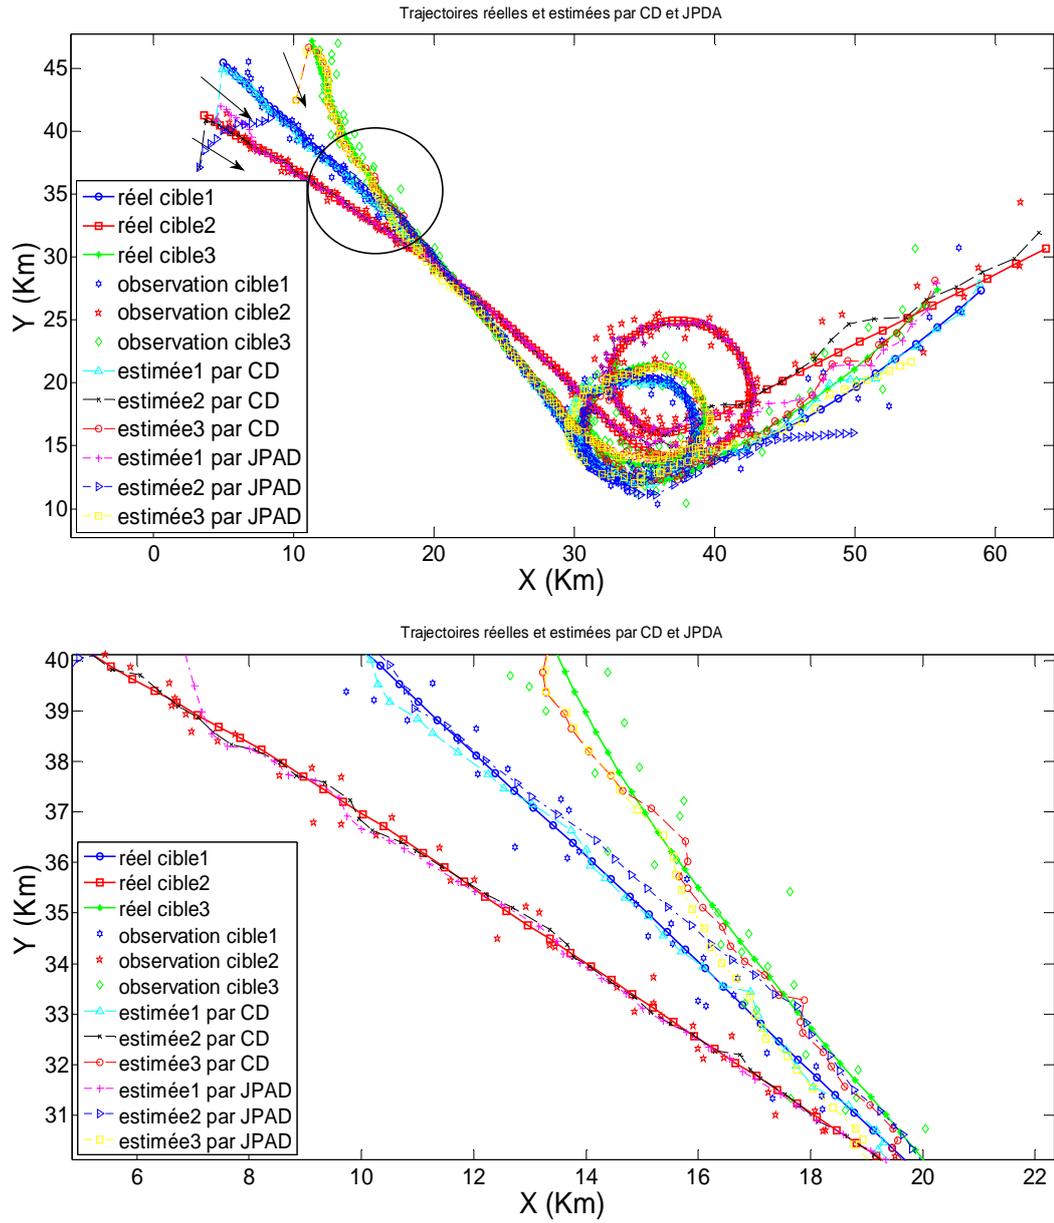


Figure 4.8 : Trajectoires réelles et estimées par CD et JPDA pour (S3, Sc4)

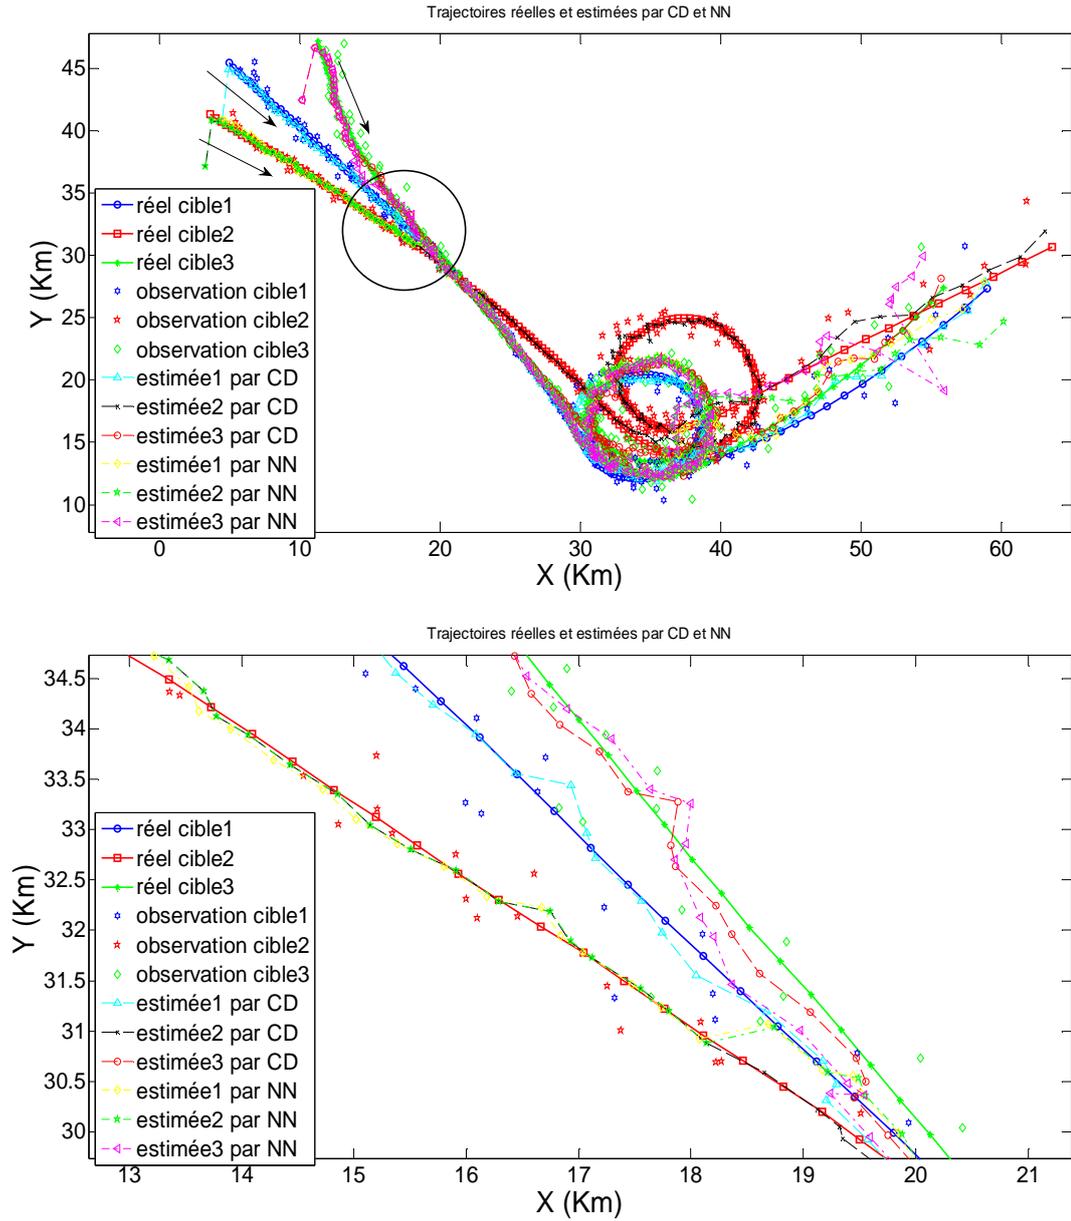


Figure 4.9 : Trajectoires réelles et estimées par CD et NN pour (S3, Sc4)

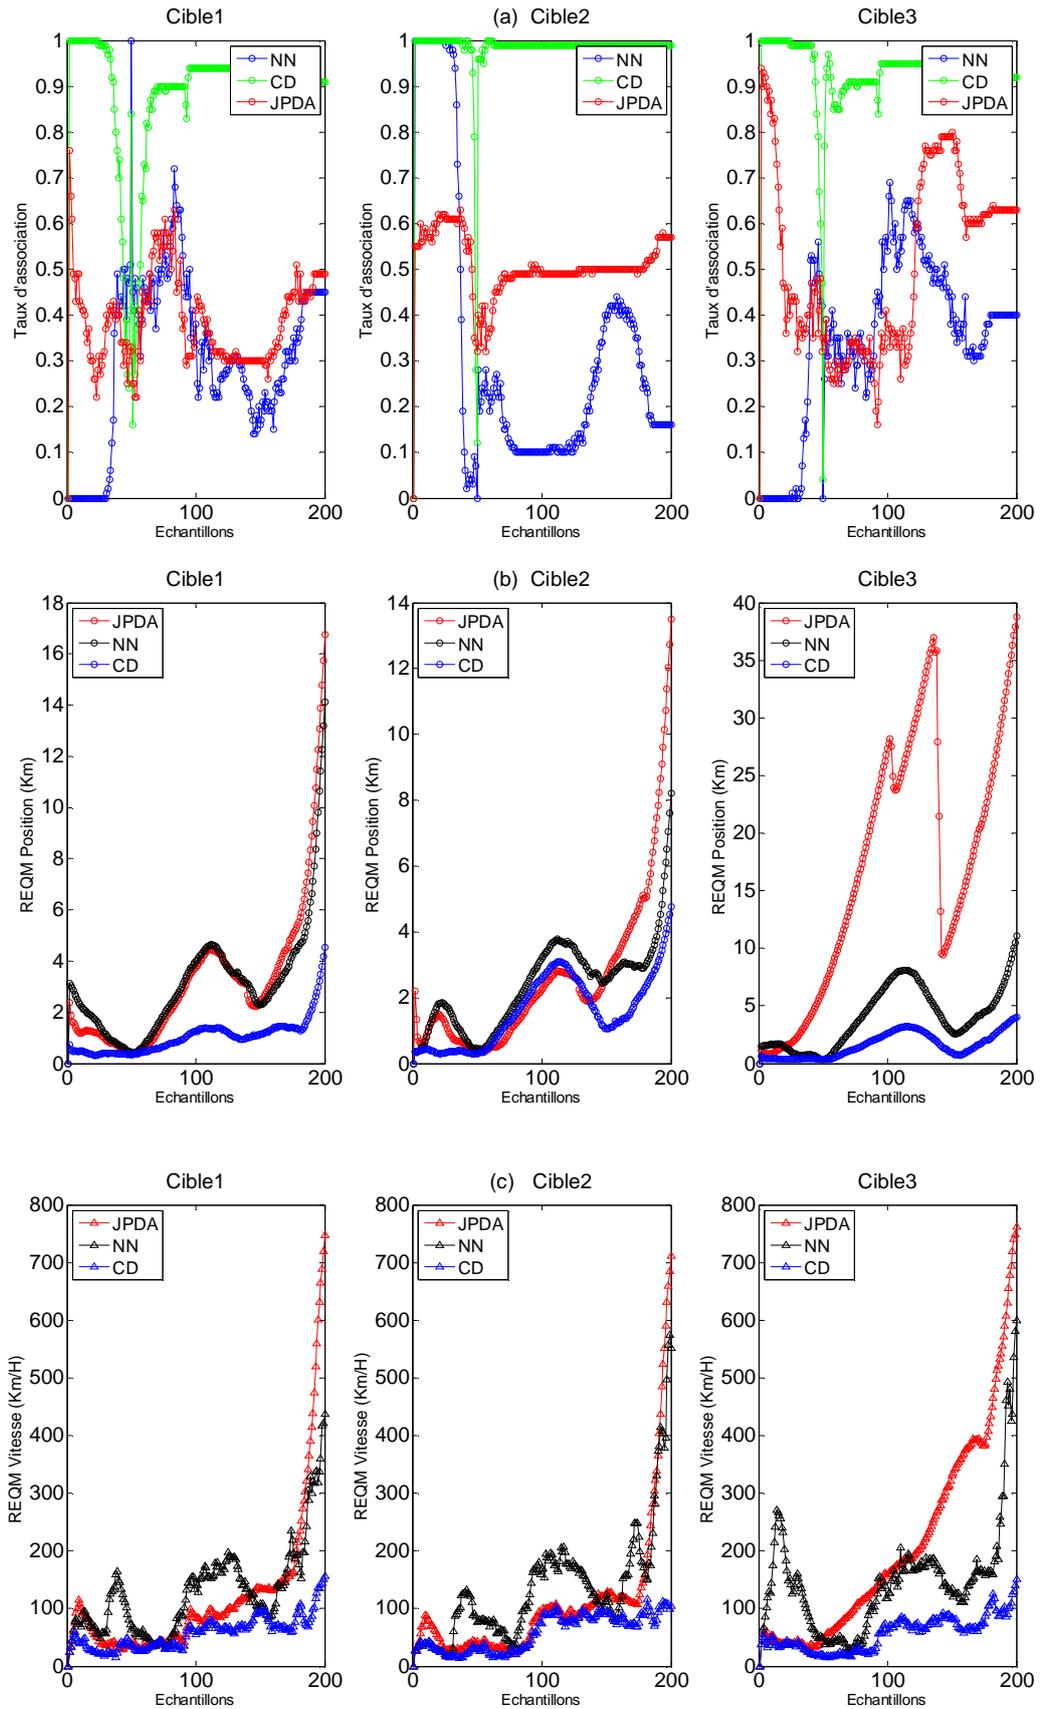


Figure 4.10 : Les mesures de performances CD, NN et JPDA pour (S3, Sc4)
 (a) taux d'association (b) REQM P (c) REQM V

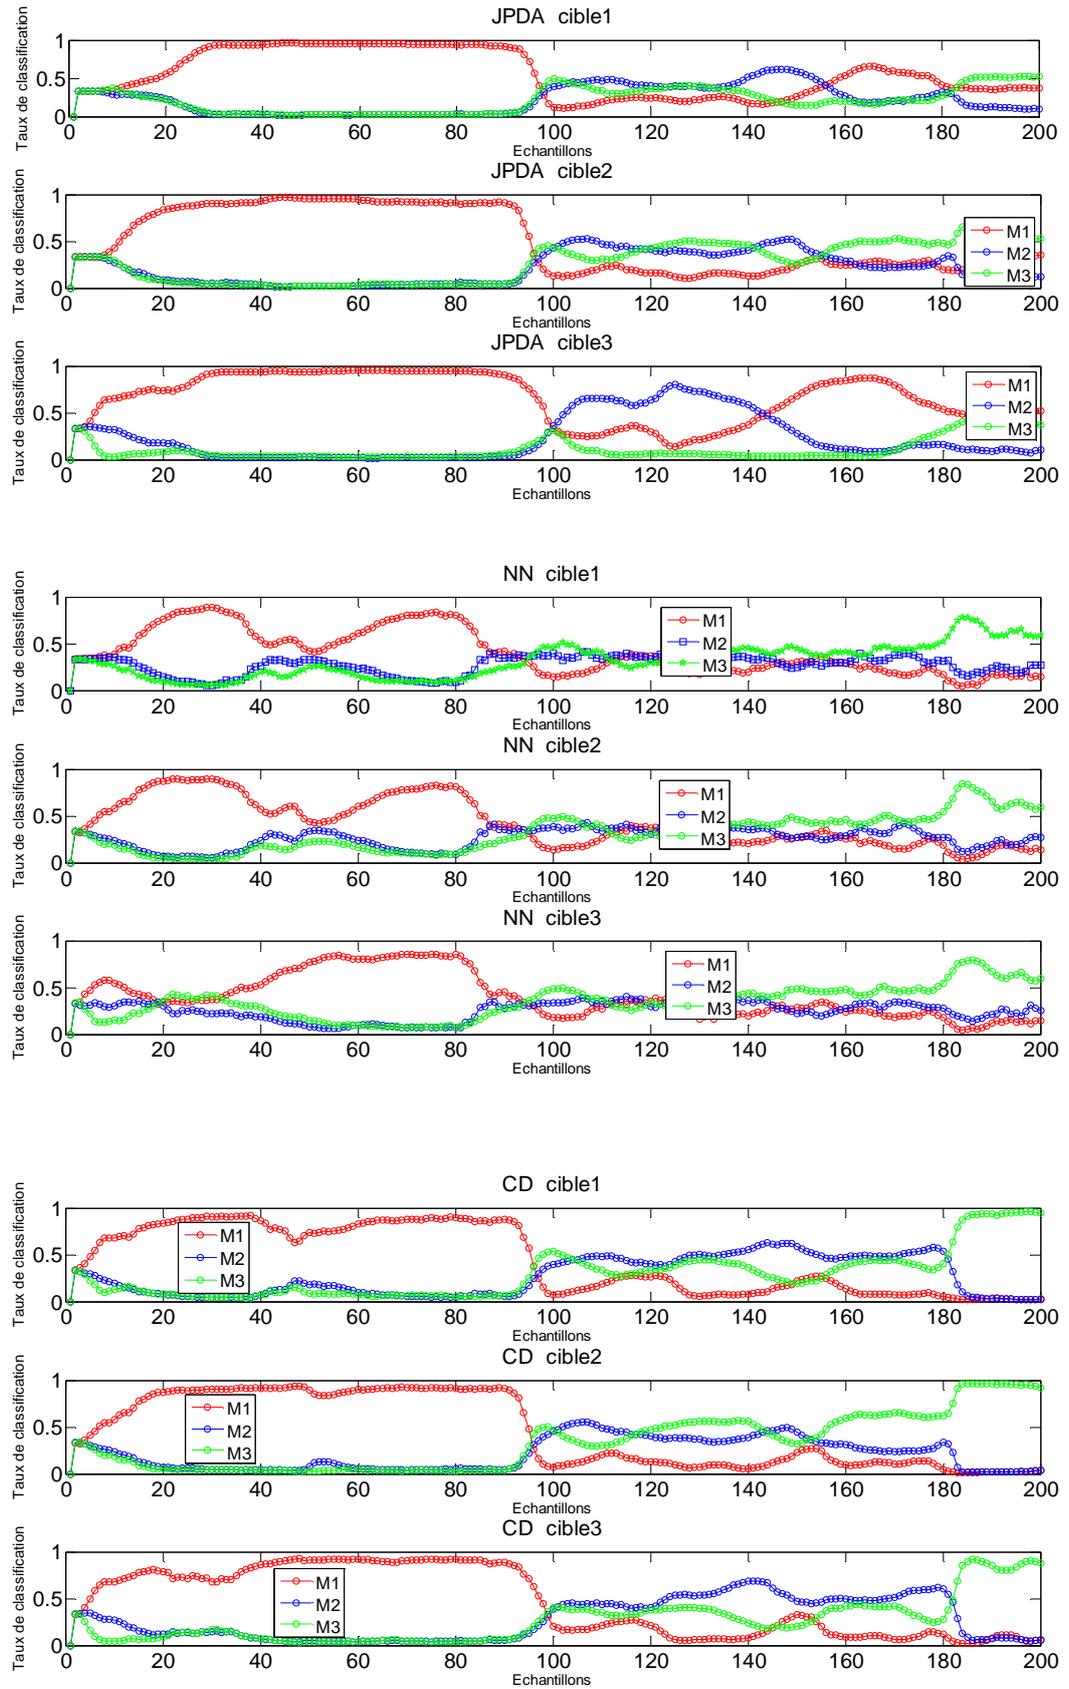


Figure 4.11 : la probabilité de classification de mouvement pour (S3, Sc4)

Les résultats obtenus, dans les figures (4.4) à (4.11), permettent de dégager les remarques suivantes :

- Les trajectoires estimées par CD, NN et JPDA dans le scénario Sc3 sont proches des trajectoires réelles. La séparation entre les cibles par CD est évidente il n'y a pas de confusion entre les cibles durant tout le trajet. Par contre la séparation entre les cibles par NN et JPDA est faible durant tout le trajet, on peut dire qu'il y a une confusion entre les cibles. Dans le scénario Sc4 les trajectoires estimées par CD sont proches de trajectoires réelles par contre pour NN et JPDA, une dégradation dans les trajectoires estimées pour le modèle M3 apparaît.
- D'une manière générale, les performances obtenues en termes de REQMP et REQMV, dans le scénario Sc3, en utilisant la méthode CD et celle des NN sont presque similaires. Celles-ci sont généralement meilleures que celles obtenues en utilisant la méthode JPDA qui prend en compte dans sa mise en œuvre de la combinaison de toutes les observations qui peut entraîner une divergence par rapport aux résultats escomptés. Cette notion de proximité constitue un inconvénient majeur pour le JPDA. Par ailleurs, dans le scénario Sc4, nous observons une nette supériorité de CD par rapport aux méthodes JPDA et NN. Cette dernière se caractérise, contrairement au premier scénario, par une dégradation de ses performances.
- D'une manière générale, les performances obtenues en termes de probabilité d'association sont meilleures en utilisant CD. En effet, pour le scénario Sc3, celles-ci présentent globalement de meilleures performances d'association que JPDA et NN. Ceci se remarque en particulier pour la cible qui se trouve au milieu des deux autres cibles. Par ailleurs, pour le scénario Sc4, la qualité de l'association obtenue par CD est meilleure par rapport aux JPDA et NN sauf pour les situations de croisement très conflictuelles pour lesquelles la probabilité d'association CD chute instantanément.
- Globalement, les performances obtenues en termes de probabilité de classification de mouvement par NN et CD sont satisfaisantes quel que soit le scénario considéré. En revanche, en ce qui concerne le JPDA, les performances obtenues sont satisfaisantes que pour le scénario Sc4, et elles sont médiocres dans le cas de cibles continument parallèles. Ainsi, on s'aperçoit très vite que les performances de poursuite influent directement sur les performances de classification.

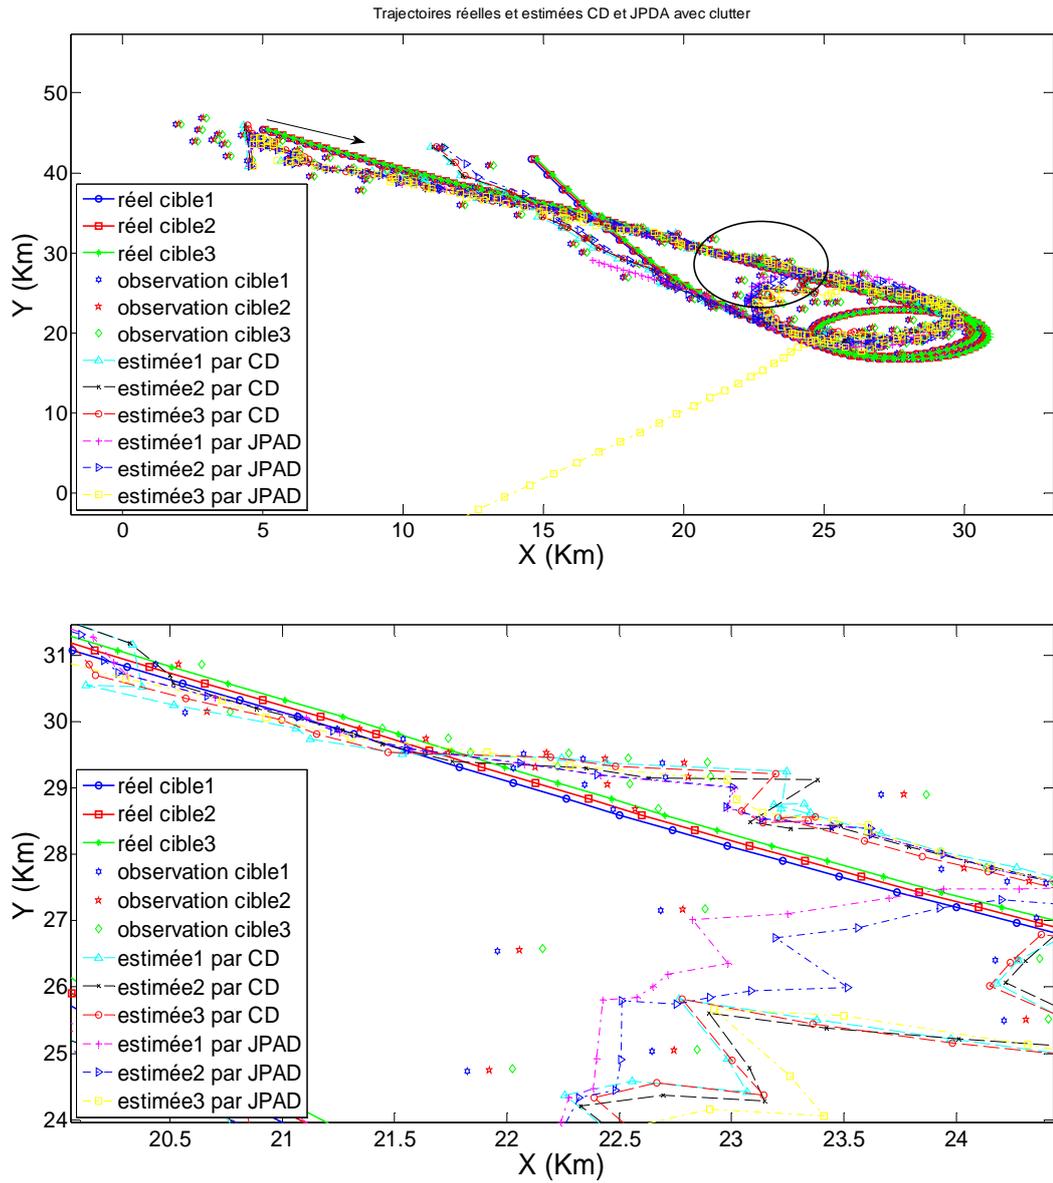


Figure 4.12 : Trajectoires réelles et estimées par CD et JPDA pour (S4, Sc3)

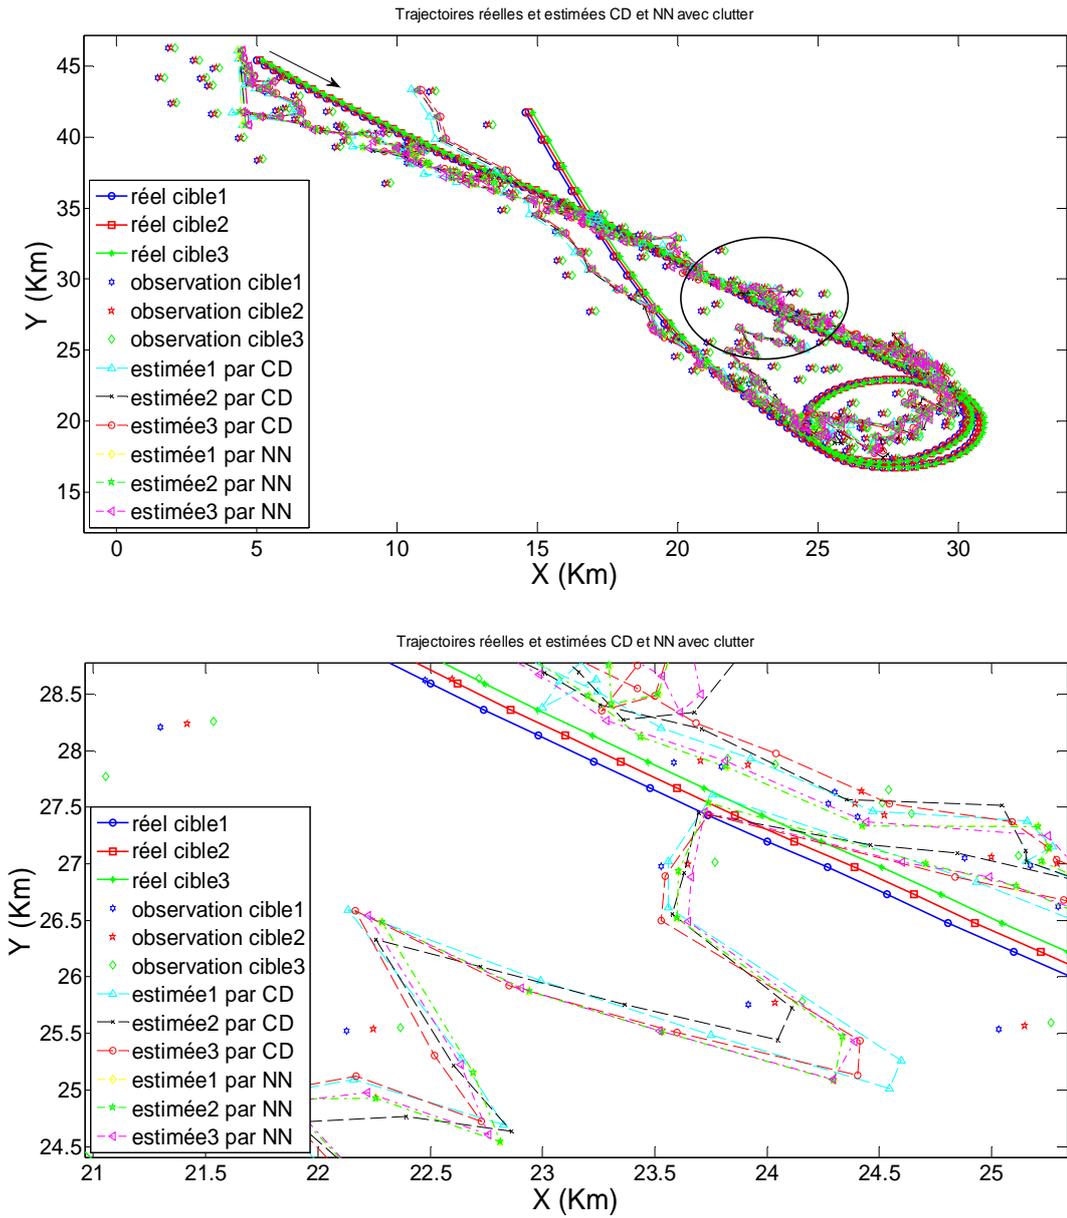


Figure 4.13 : Trajectoires réelles et estimées par CD et NN pour (S4, Sc3)

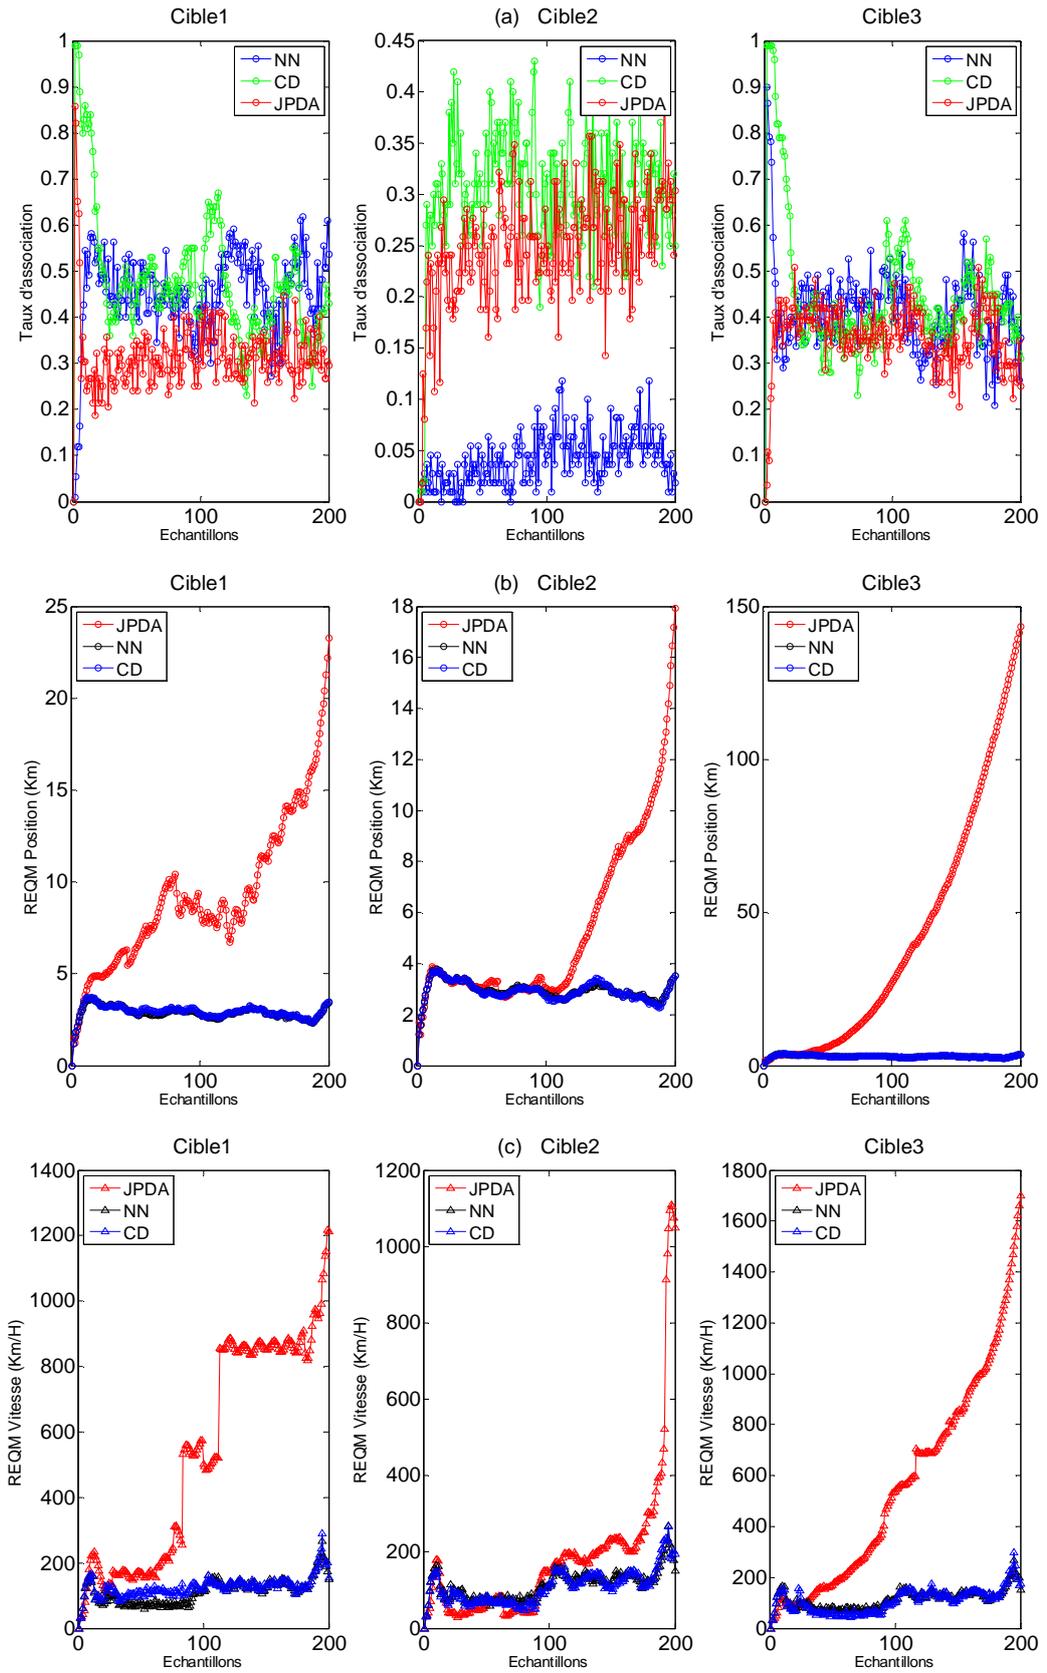


Figure 4.14 : Les mesures de performances CD, NN et JPDA pour (S4, Sc3)
 (a) taux d'association (b) REQM P (c) REQM V

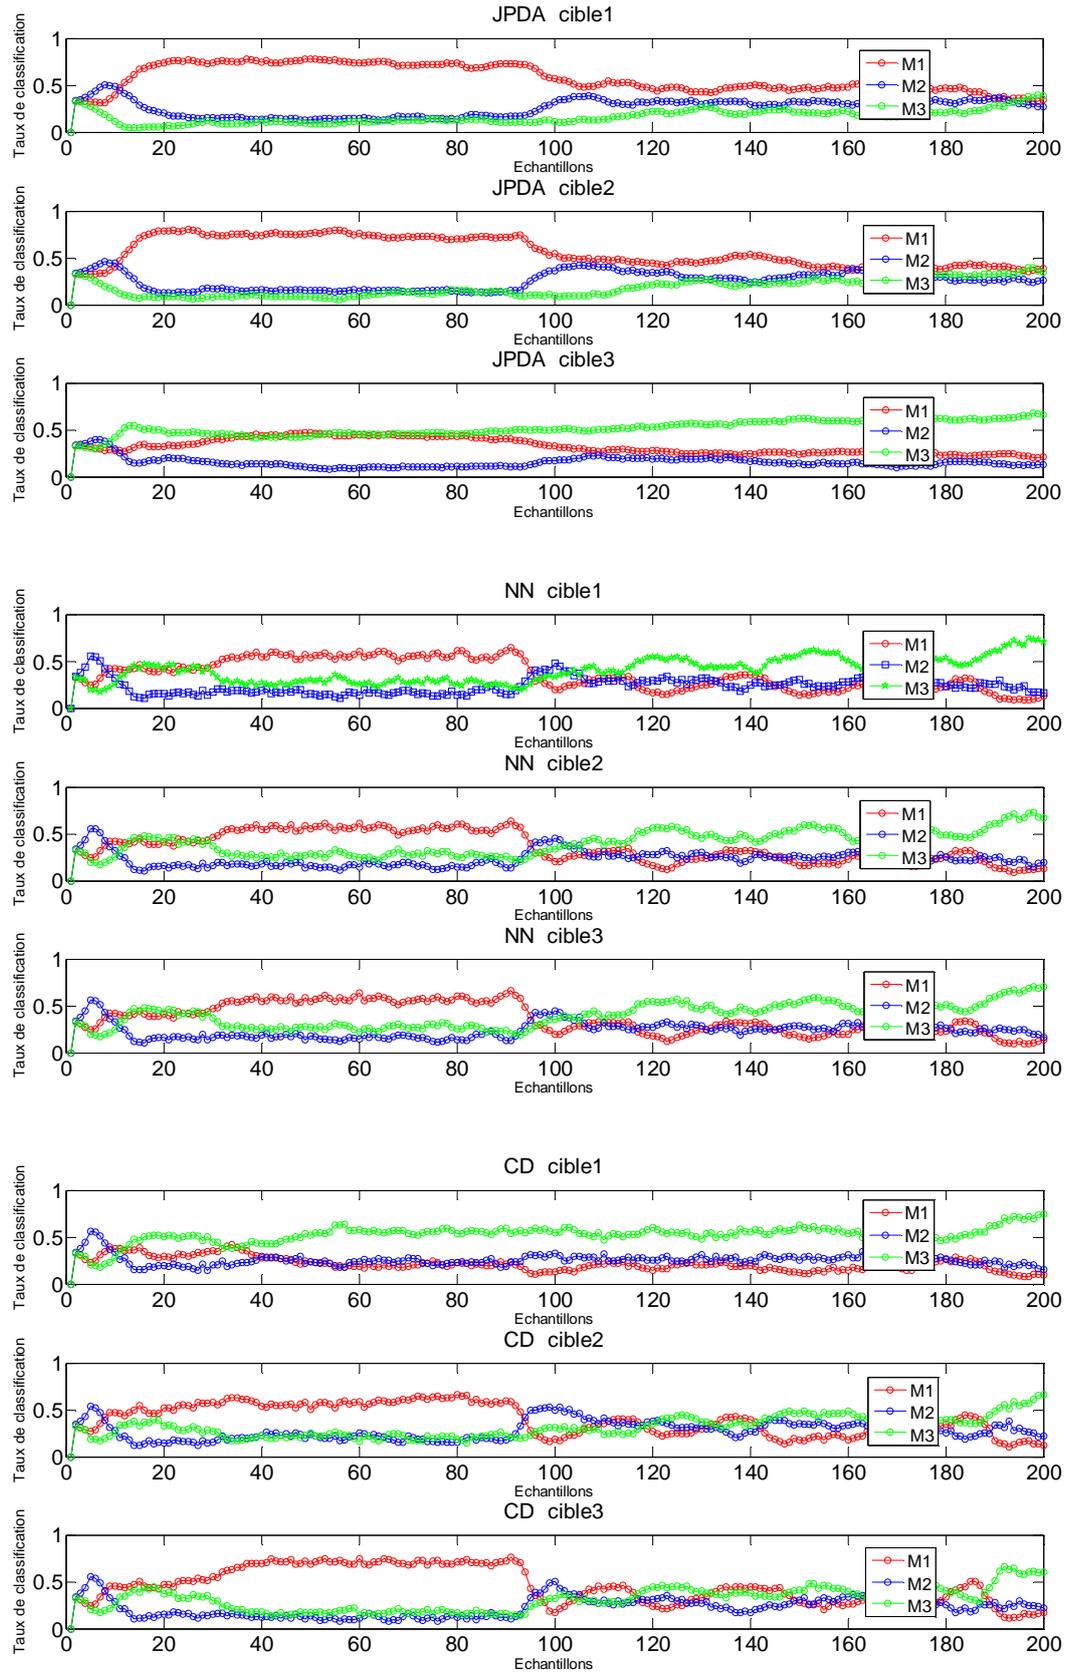


Figure 4.15 : la probabilité de classification de mouvement pour (S4, Sc3)

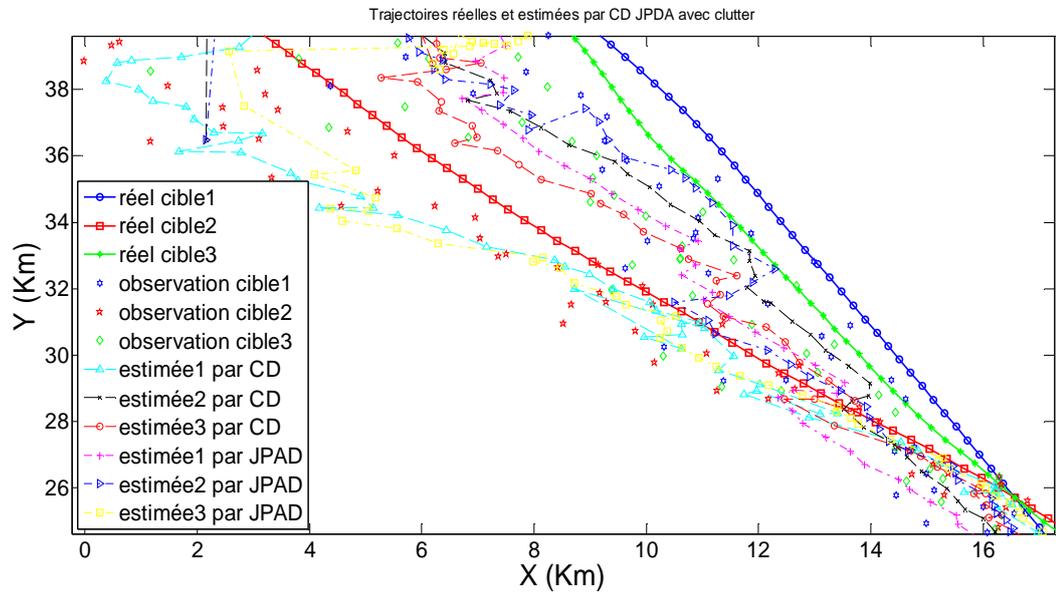
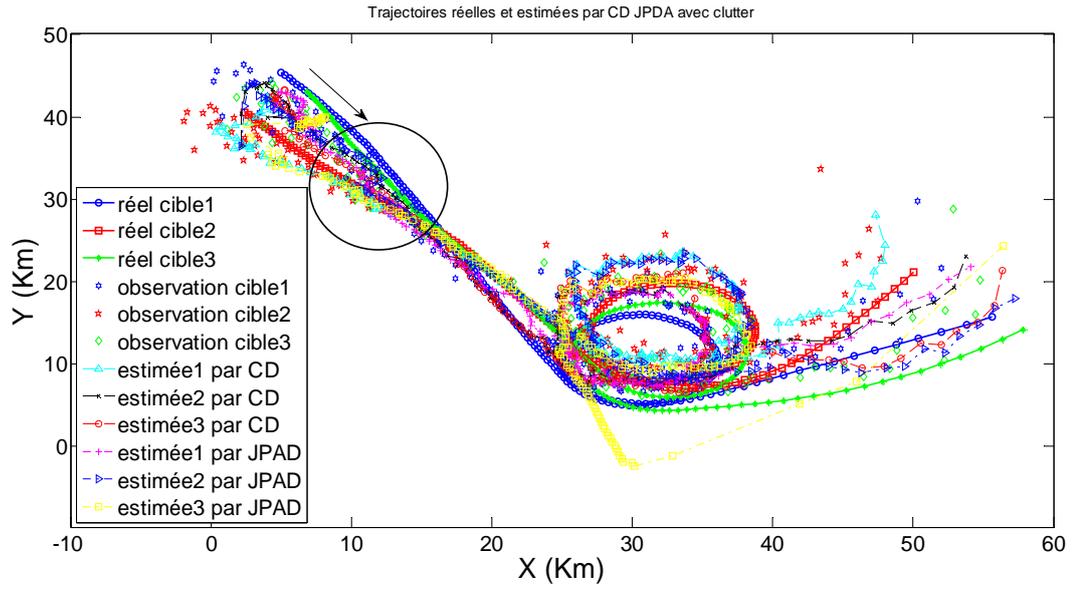


Figure 4.16 : Trajectories réelles et estimées par CD et JPDA pour (S4, Sc4)

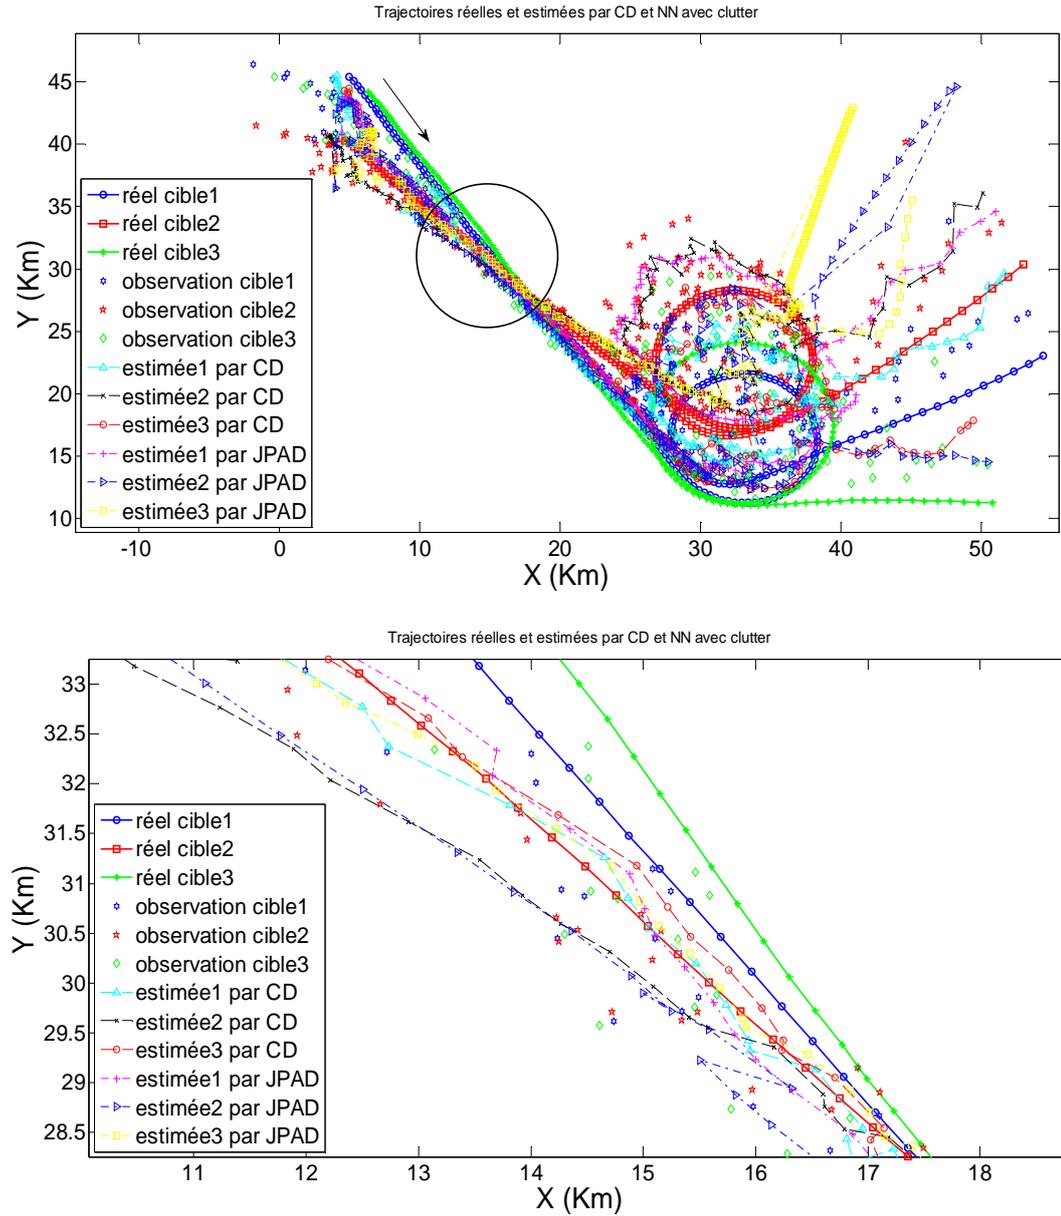


Figure 4.17 : Trajectoires réelles et estimées par CD et NN pour (S4, Sc4)

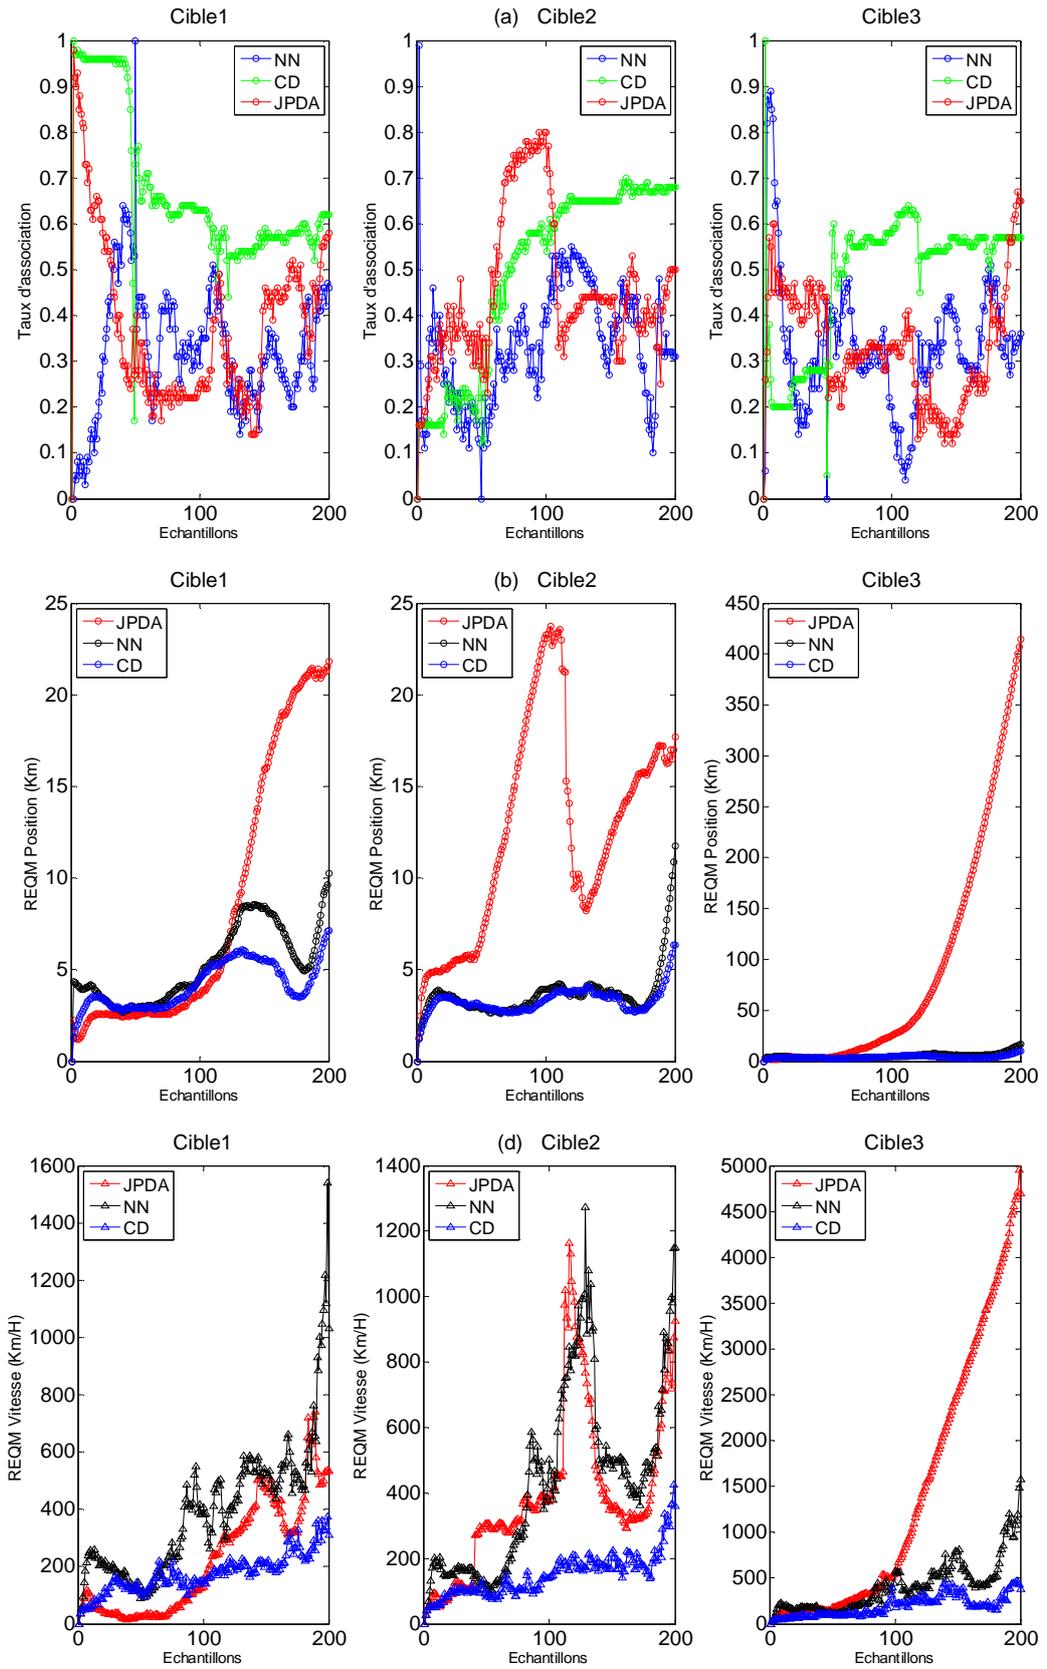


Figure 4.18 : Les mesures de performances CD, NN et JPDA pour (S4, Sc4)
 (a) taux d'association (b) REQM P (c) REQM V

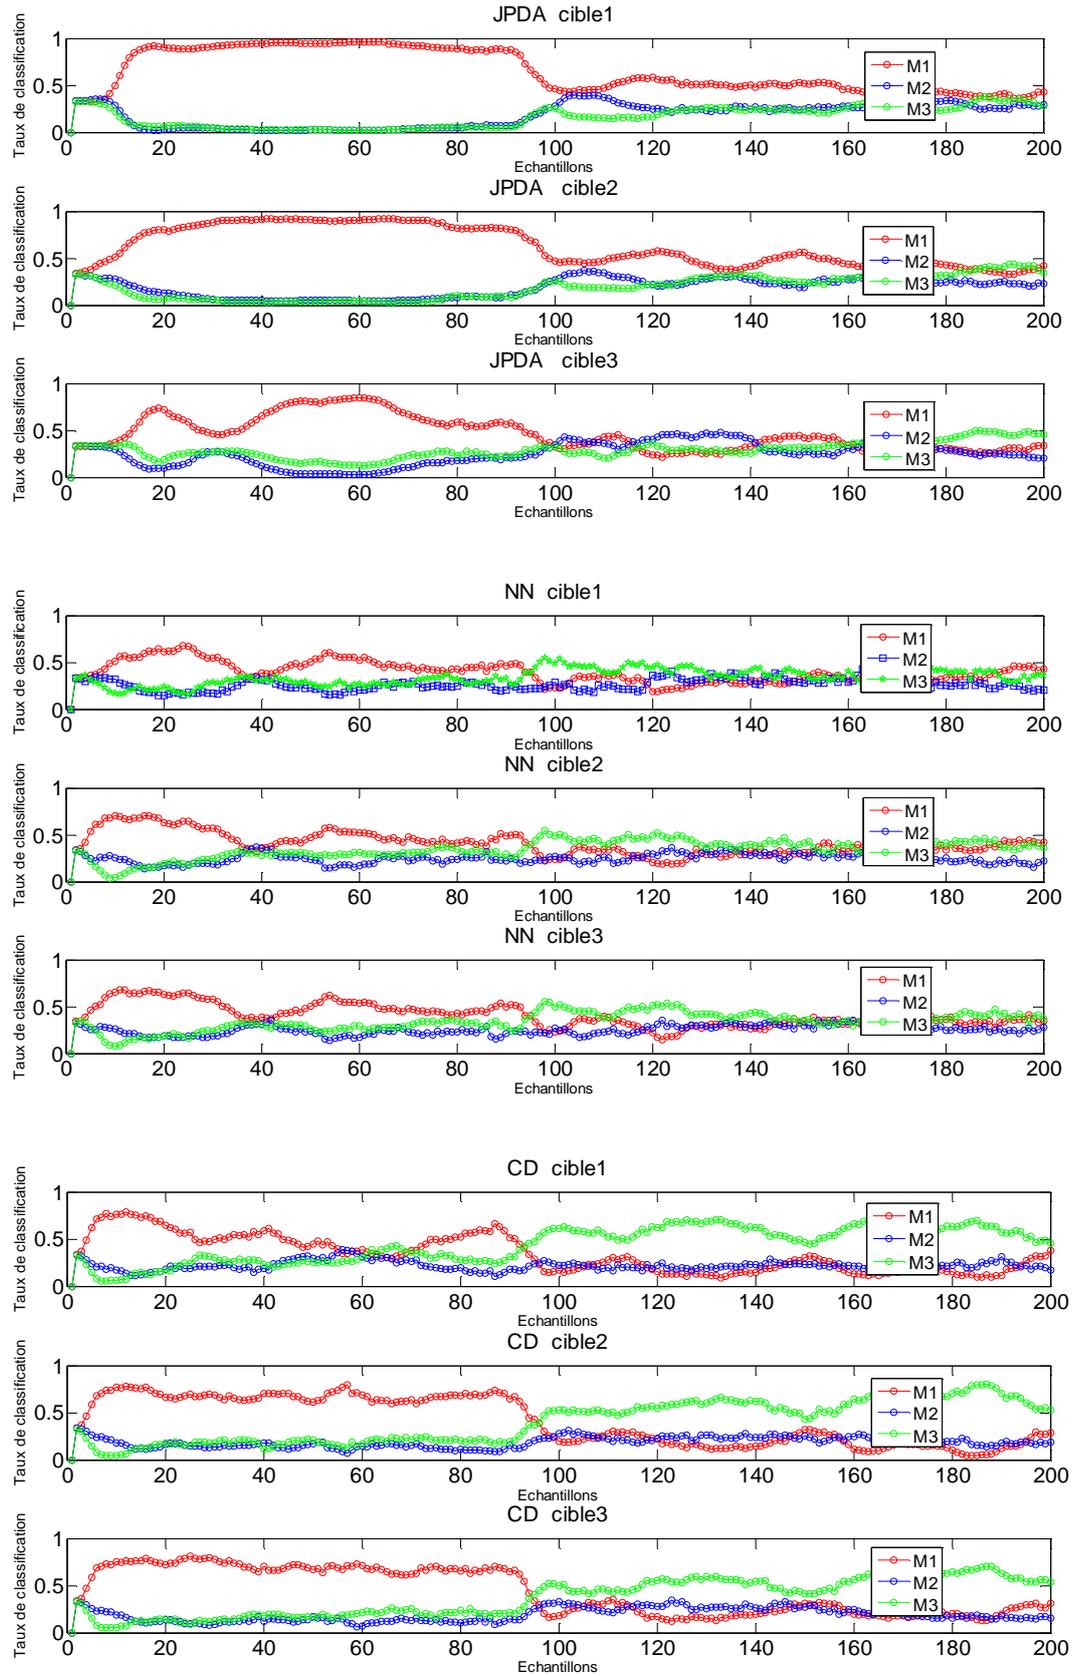


Figure 4.19 : la probabilité de classification de mouvement pour (S4, Sc4)

Dans cette simulation nous avons étudié les performances de la poursuite multi-cibles et la classification de mouvements avec la présence de clutter de terre (S4). Les résultats obtenus, dans les figures (4.12) à (4.19), permettent de dégager les remarques suivantes :

- Les trajectoires estimées par CD, NN et JPDA dans le scénario Sc3 sont un peu loin des trajectoires réelles. La séparation entre les cibles par CD est évidente, il n'y a pas de confusion entre les cibles durant tout le trajet. La séparation entre les cibles est moins bonne pour JPDA par contre il y a une confusion entre les cibles pour la méthode NN. Dans le scénario Sc4 une dégradation dans les trajectoires estimées par CD, NN et JPDA et surtout pour le modèle M2 et M3 est observée.
- D'une manière générale les performances obtenues en termes de REQMP et REQMV en utilisant la méthode CD sont les meilleurs. Par ailleurs, les bonnes performances obtenus par CD (similaires à celles obtenues par NN), se dégradent dans les cas de croisement de cibles. Dans le scénario Sc4 nous observons une nette supériorité de CD par rapport aux méthodes NN et JPDA.
- D'une manière générale, les performances obtenues en termes de probabilité d'association sont les meilleurs en utilisant CD. En effet, les résultats qui apparaissaient dans le scénario Sc4 confirment avec intelligibilité les conclusions émises. En ce qui concerne le scénario Sc3, les conclusions ultérieures sont confirmées dans le cas de la deuxième cible. Nous remarquons une dégradation de taux d'association par rapport à la situation S3 ceci est dû à la présence d'un clutter pointu.
- D'une manière générale, une légère préférence est accordée aux CD et aux NN pour la classification de mouvements. Par ailleurs nous constatons que lors de présence de clutter, la détection du changement de modèle lorsqu'elle est effective est retardé.

4.7. Conclusion

Dans ce chapitre nous avons effectué une étude sur la poursuite multi-cibles et la classification de mouvements, en utilisant les IMM associés au filtre de Kalman étendu, l'aspect multi-cibles est illustré par trois méthodes d'association de données « JPDA, NN et CD ». Nous avons effectué une comparaison de trajectoires estimées et de performances en termes de REQMP et REQMV, probabilité d'association et probabilité de classification de mouvements pour divers scénarios. Nous avons considéré deux situations, avec et sans présence de clutter (fouillis) donc il y'a une grande ambiguïté lors de l'association de donnée. Les résultats de simulation ont montré que :

- En termes de REQMP et REQMV, CD a présenté des bonnes performances par rapport aux JPDA et NN dans les divers scénarios. Donc CD est robuste dans les situations de grande ambiguïté.
- Par ailleurs, la qualité de l'association obtenue par CD est très satisfaisante. En effet, les probabilités d'association obtenues avoisinent très souvent l'unité en dehors :
 - des situations de grande ignorance (cible évoluant en général entre deux cibles proches).
 - des situations de croisement très conflictuelles pour lesquelles la probabilité d'association chute à zéro.
 - Présence de clutter (fouillis)
- La détection du modèle de mouvement n'est pas instantanée à cause de l'ambiguïté lors de l'association de données du à la présence d'un clutter.
- Après l'association par JPDA, nous remarquons une bonne classification de mouvement pour le Scénario Sc4, mais cette classification se détériore pour le scénario Sc3.
- CD et NN donnent des performances de classification de mouvements similaires et meilleurs par rapport aux JPDA dans les deux scénarios Sc3 et Sc4.
- La méthode d'association de données par CD présente une supériorité des performances dans tous les termes dans le cas ou intervient le clutter, la méthode est robuste en la présence de clutter.

CONCLUSION

Dans le domaine de la poursuite multi-cibles, l'association de données joue un rôle très important surtout pour la poursuite des cibles proches ou l'ignorance sur l'association est grande.

Le problème d'association de données dans la poursuite multi-cibles a été largement traité par plusieurs approches telles que la méthode de plus proches voisins (NN) et le filtre d'association de données par probabilités conjointes (JPDA). L'inconvénient majeur de ces méthodes réside dans l'exigence de la connaissance de la probabilité a priori, qui n'est malheureusement pas connue avec certitude.

Dans ce travail nous avons exploré une approche qui permet de gérer aussi bien les données incertaines et imprécises basée sur la théorie de "Dempster-Shafer". Nous nous sommes intéressés à la combinaison de Dempster dans la théorie de l'évidence pour l'association de données.

Une comparaison en termes de trajectoires estimées, probabilité de bonne association, probabilité de classification de mouvement et l'erreur quadratique moyenne en vitesse et position a été faite entre les méthodes d'association de données NN, JPDA et CD, les résultats obtenus mettent essentiellement en relief les points suivants :

- L'association de données par CD est plus performante que les méthodes d'association de données NN et JPDA en termes de trajectoires estimées et l'erreur quadratique moyenne en position et en vitesse.
- La méthode d'association de données par CD a une supériorité par rapport aux méthodes NN et JPDA en termes de probabilité de bonne association et de classification de mouvements.

- L'association obtenue par CD est très satisfaisante. En effet les probabilités d'association avoisinent souvent l'unité sauf pour les cas de cible évoluant entre deux cibles, situation de croisement des cibles et lors de présence de clutter (fouillis).
- Le cas de présence de clutter (fouillis) de surface (terre ou mer) a montré une dégradation des performances pour toutes les méthodes considérées. Cependant, la méthode d'association de données par CD reste la plus robuste.

Nous proposons comme extensions de ce travail les points suivants :

- Utilisation d'un réseau de capteurs dans le but d'améliorer les performances d'association et de classification de mouvements.
- Inclure d'autres schémas de modélisation des données pour assurer une comparaison fiable des résultats.
- Dans le but d'assurer une poursuite multi-cibles évidentes, nous comptons appliquer la théorie des jeux qui est susceptible d'apporter un nouvel éclairage dans les scénarios de grande ignorance.

APPENDICE A

Distribution de Weibull

- Une variable aléatoire X est dite pour être Weibull distribuée, si sa densité de probabilité à deux paramètres α et β , notée $W(\alpha, \beta)$, est définie sur \mathbb{R}^+ par :

$$f_x(x) = \frac{\beta}{\alpha} \left(\frac{x}{\alpha}\right)^{\beta-1} \exp\left[-\left(\frac{x}{\alpha}\right)^\beta\right], \alpha > 0, \beta > 0$$

α représente le paramètre d'échelle et β le paramètre de forme de la distribution Weibull. Enfin, la distribution Weibull d'un seul paramètre est obtenue lorsque $\alpha = 1$. Elle est alors appelée distribution Weibull standard. Sa PDF se résume donc à :

$$f_x(x) = \beta x^{\beta-1} \exp(-x^\beta)$$

- **Fonction de répartition**

La fonction de répartition de X , est représentée par:

$$F_x(x) = 1 - \exp\left[-\left(\frac{x}{\alpha}\right)^\beta\right]$$

- **Moments d'ordre n**

$$\mu_n = E[X^n] = \alpha^n \Gamma\left(1 + \frac{n}{\beta}\right)$$

- Ce qui donne une moyenne (n=1)

$$E[X] = \alpha \Gamma\left[\frac{1}{\beta} + 1\right]$$

- Une puissance moyenne (n=2)

$$E[X^2] = \alpha^2 \Gamma\left[\frac{2}{\beta} + 1\right]$$

- Et donc une variance

$$\text{Var}(X) = \alpha^2 \left[\Gamma\left(1 + \frac{2}{\beta}\right) - \Gamma^2\left(1 + \frac{1}{\beta}\right) \right]$$

Notons que sous *Matlab*, nous générons une variable aléatoire Weibull par la commande `weibrnd(α , β)`, où α est le paramètre d'échelle et β , le paramètre de forme. Nous pouvons l'initialiser par la commande `rand('state',0)`.

- **Lien entre la loi Weibull et autres lois**

Pour $\beta=1$, la loi Weibull se réduit à une loi Exponentielle donnée par:

$$f_x(x) = \frac{1}{\alpha} \exp\left[-\frac{x}{\alpha}\right]$$

Pour $\beta=2$, la loi Weibull se réduit à une loi Rayleigh donnée par:

$$f_x(x) = \frac{2x}{\alpha^2} \exp\left[-\frac{x^2}{\alpha^2}\right]$$

APPENDICE B

Mesure des Performances

À présent, nous décrivons la mesure de performances associées à une cible i particulière. On distingue principalement Quatre indicateurs de performance qui sont :

- **Le RMSE en position**

L'erreur quadratique moyenne en position au sens des moindres carrés notée e_{ki}^{pos} ou Root Mean Square Error (RMSE) d'une cible i à l'itération k se calcule en moyennant l'erreur entre la position réelle d'une cible $(x_{k,i}, y_{k,i})$ et sa position estimée $(\hat{x}_{k,i}^n, \hat{y}_{k,i}^n)$, telle que :

$$e_{ki}^{pos} = \sqrt{\frac{1}{N_{k,i}^{MC}} \sum_{n=1}^{N^{MC}} ((x_{k,i} - \hat{x}_{k,i}^n)^2 + (y_{k,i} - \hat{y}_{k,i}^n)^2)}$$

Où N^{MC} est le nombre de jeux de Monte-Carlo effectués, $N_{k,i}^{MC}$ est le nombre de jeux de Monte-Carlo à l'itération k où la cible i est associée à une cible et les vecteurs $(x_{k,i}, y_{k,i})$ et $(\hat{x}_{k,i}^n, \hat{y}_{k,i}^n)$ représentent les positions réelles et estimées de la cible i à l'itération k avec le jeu de mesures n .

- **Le RMSE en vitesse**

De même que pour l'équation de l'erreur quadratique moyenne en vitesse est calculée de la façon suivante :

$$e_{ki}^{vit} = \sqrt{\frac{1}{N_{k,i}^{MC}} \sum_{n=1}^{N^{MC}} ((\dot{x}_{k,i} - \hat{\dot{x}}_{k,i}^n)^2 + (\dot{y}_{k,i} - \hat{\dot{y}}_{k,i}^n)^2)}$$

Avec les vecteurs $(\dot{x}_{k,i}, \dot{y}_{k,i})$ et $(\hat{\dot{x}}_{k,i}^n, \hat{\dot{y}}_{k,i}^n)$ représentant les vitesses réelles et estimées de la cible i à l'itération k .

- **La continuité de poursuite**

La continuité de poursuite d'une cible i est une mesure qui permet de suivre les interruptions dans l'association d'une mesure à une cible réelle i . Si à une cible i à l'itération k $x_{k,i}$ peut être associée une estimation $\hat{x}_{k,i}^n$ alors la continuité de poursuite est assurée et la continuité pour le jeu de mesure n , $\iota_{k,i}^n$ est égale à 1 (elle est égale à 0 sinon).

Finalement, les résultats sont moyennés sur l'ensemble des jeux de Monte-Carlo tel que :

$$\bar{\iota}_{k,i} = \frac{1}{N^{MC}} \sum_{n=1}^{N^{MC}} \iota_{k,i}^n$$

- **Le taux d'association des données**

Un dernier enjeu dans le cadre de la poursuite multi-cible est de réussir à associer une cible à une seule mesure. Il est égal à 1 dès qu'une cible est associée à une nouvelle mesure. Par conséquent, le taux d'association de mesure $\bar{\iota}_{k,i}$ d'une cible i est défini tel que $\bar{\iota}_{k,i}^n = 1$, si une cible i est associée à une mesure P_1 à l'itération $k-1$ et à une mesure P_2 à l'itération k ou si la cible n'était associée à aucune piste à l'itération $k-1$. Il est égal à 0 sinon. Finalement, les résultats sont moyennés sur l'ensemble des jeux de Monte-Carlo tel que :

$$\bar{\iota}_{k,i} = \frac{1}{N^{MC}} \sum_{n=1}^{N^{MC}} \bar{\iota}_{k,i}^n$$

L'ensemble de ces critères permet d'avoir un aperçu complet des capacités de poursuite multi-cible : Capacité à évaluer de façon correcte le nombre de cibles sur la zone d'observation et à créer les bonnes associations, robustesse par rapport aux fausses alarmes.

Capacité à discriminer les cibles proches. Cependant, représenter chaque aspect des performances par une mesure de performance particulière n'est pas toujours lisible. C'est pourquoi, les auteurs, en particulier Hoffman et Mahler [31], se sont intéressés à les performances pour faire apparaître, avec une seule métrique la supériorité ou non d'un algorithme.

APPENDICE C

Distribution Lognormal

La distribution lognormal a été développée dans le but d'être appliquée dans une grande variété de situations réelles de clutter de mer et de terre à faible angle d'incidence (low grazing angle) et dans les radars à haute résolution. C'est une loi de distribution dont le logarithme est normalement distribué. Par définition, une variable aléatoire X suit une loi lognormal, notée $X : \ln(\mu, \sigma^2)$, quand sa densité de probabilité bi paramétrique s'écrit :

$$f_x(x) = \frac{1}{x\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{\ln x - \mu}{\sigma}\right)^2\right] \sigma \geq 0$$

μ est la moyenne de $\ln x$, représente le paramètre d'échelle et σ l'écart type de $\ln x$ est connu sous le nom de paramètre de forme. Le fait d'augmenter la valeur de μ en maintenant celle de σ constante a pour effet d'aplatir la PDF et de l'étirer à droite, en conservant sa forme. Tandis que le paramètre de forme σ , comme son nom l'indique, définit la forme de la distribution. Le paramètre $\rho = e^{\sigma^2/2}$ représente le rapport moyenne-à-médiane, qui peut être utilisé pour représenter la forme. Les investigations sur les données réelles de clutter ont donné des valeurs de ρ variant de 1.065 à 1.93. Par conséquent, σ varie dans la plage 0.355 à 1.147.

- **Fonction de répartition**

La fonction de répartition de X , est représentée par:

$$F_x(x) = \frac{1}{2} + \frac{1}{2} \operatorname{erf}\left[\frac{\ln x - \mu}{\sigma\sqrt{2}}\right]$$

- **Moments d'ordre n**

$$E[X^n] = \exp\left[n\mu + \frac{n^2}{2}\sigma^2\right]$$

- Ce qui donne une moyenne (n=1):

$$E[X] = \exp\left[\mu + \frac{\sigma^2}{2}\right]$$

- Une puissance moyenne (n=2):

$$E[X^2] = \exp\left[2(\mu + \sigma^2)\right]$$

Et donc une variance:

$$\text{Var}[X] = \exp(2\mu + \sigma^2)(\exp(\sigma^2) - 1)$$

- **Lien entre la loi lognormal et la loi Normal**

Si la variable aléatoire Y suit une loi lognormal, notée $Y \sim \text{Ln}(\mu, \sigma^2)$, alors la variable aléatoire $X = \text{Ln}(Y)$ suit une loi normal, notée $X \sim \text{N}(\mu, \sigma^2)$, (Ln étant le logarithme Népérien).

Notons que sous *Matlab*, nous générons une variable aléatoire lognormal par la commande `lognrnd(μ, σ)`, où μ est le paramètre d'échelle et σ , le paramètre de forme. Cette commande peut être remise à zéro par la commande `randn('state', 0)`.

REFERENCES

1. A. Mamdouh Abdel Aziz, "New data fusion algorithms for distributed multi-sensor multi-target environments", Doctoral dissertation, Naval Postgraduate School, Monterey-California-USA, (September 1999).
2. T. Kirubarajan, Y. Bar-Shalom, "Probabilistic data association techniques for target tracking in clutter", IEEE review, v. 92, issue. 3, (march 2004), 536 - 557.
3. K. Chang, S. Mori, and C.Y Chong, "Performance evaluation of a multiple-hypothesis multi-target tracking algorithm", Proceedings of the 29th IEEE Conference on decision and control, Honolulu, Hawaii-USA, (5-7 December 1990).
4. P. Fortemps, "Fuzzy sets for modelling and handling imprecision and flexibility", Polytechnic faculty of Mons, Belgium, (1996-1997).
5. D. Gruyer, "Etude du traitement de données imparfaites pour le suivi multi objets : Application aux situations routières". Thèse de doctorat, université de Technologie de Compiègne, (1999).
6. E. LEFEVRE, "Fusion adaptée d'informations conflictuelles dans le cadre de la théorie de l'évidence, application au diagnostic médical", Thèse de doctorat, Institut National des Sciences Appliquées de Rennes, Rennes -FRANCE, (22 Novembre 2001).
7. Koch. W, "Advanced Target Tracking Techniques. In Advanced Radar Systems", Signal and Data Processing, (2007), 2-34.
8. M. Mariton, "Pistage de cibles manoeuvrantes : synthèse et apport de l'imagerie", Traitement du Signal, V.10, n°2, (1998).
9. Jason L. Williams, "Gaussian Mixture Reduction for Tracking Multiple Maneuvering Targets in Clutter", Thesis, (2003).
10. C.Blondel, A.Guillbert, E.Sifferedi, "caractérisation et modélisation de la trajectoire et des mouvements des mobiles manoeuvrantes", huitième colloque sur le traitement de signal et ses applications, Nice, (1 au 5 juin 1981), 458-460.

11. V. Nimier, A. Appriou, "Utilisation de la Théorie de Dempster-Shafer pour la Fusion d'information", quinzisième colloque, Grets Juan les Pins, (18 au 21 septembre 1995).
12. Shafer. G, "A Mathematical Theory of Evidence", Princeton University Press, New Jersey, (1976).
13. Dempster. A, "Upper and lower probabilities induced by multivalued mapping", *Annals of Mathematical Statistics*, AMS-38, (1967), 325-339.
14. J.F. Baldwin, J. Lawry, T.P. Martin, "A mass assignment based ID3 algorithm for decision tree induction". *Int. J. Intell. Systems*, Vol. 12, (1997), 523–552.
15. Smarandache. F, Dezert. J, "Advances and Applications of DS_mT for Information Fusion", *Collected Works*, vol. 1, American Research Press, Rehoboth, (2004).
16. Djiknavorian. P, "Fusion d'informations dans un cadre de raisonnement de Dezert-Smarandache appliquée sur des rapports de capteurs ESM", *Mémoire de maîtrise*, Université Laval, QUEBEC, (2008).
17. Thierry DENOEU, "Théorie des fonctions de croyance: application en reconnaissance de formes et en fusion d'informations", Université de Technologie de Compiègne 3, (décembre 2010).
18. P. Smets, M. Henrion, L. N. Kanal, J.F. Lemmer, "Constructing the pignistic probability function in a context of uncertainty", *Uncertainty in Artificial Intelligence*, Vol. 5, Amsterdam, North-Holland, (1990), 28-40.
19. A. Dempster, "A generalization of bayesian inference", *Journal of the Royal Statistical Society, Series B*, vol. 30, (1968) , 205–245.
20. P. Smets, "The combination of evidence in the transferable belief model" *IEEE Trans, on Pattern Analysis and Machine Intelligence*, vol. 12, n° 5, (1990), 447–458.
21. D. Gruyer, "Etude du traitement de données imparfaites pour le suivi multi-objets : Application aux situations routières", PhD thesis, Université de Technologie de Compiègne, 1999.
22. N. Megherbi, S. Ambellouis, O. Colot, F. Cabestaing, "Multimodal data association based on the use of belief functions for multiple target tracking", In 8th International conference on Information Fusion, Philadelphia-USA, 25-28 July 2005 .

23. T. Denoeux, "A k-nearest neighbour classification rule based on Dempster-Shafer theory" *Systems, Man and Cybernetics review*, vol. 25, issue. 5, May 1995, 804-813.
24. P. Walley, "Belief function representations of statistical evidence", *The Annals of Statistics*, vol. 15, no. 4, 1987, 1439-1465.
25. P. Smets, "Bayes theorem generalized for belief functions", *ICAI-86*, vol II, 1986, 169-171.
26. GUAN .Xin, YI .Xiao, HE. You, "An Improved Dempster-Shafer Algorithm for Resolving the Conflicting Evidences Research Institute of Information Fusion", *Naval Aeronautical Engineering Institute, Yantai, China International Journal of Information Technology*, Vol. 11, No. 12, (2005).
27. A. Appriou, "Probabilités et incertitude en fusion de données multi-senseurs", *Revue Scientifique et Technique de la Défense*, (1991), 11: 27 - 40.
28. Guy .Kouemou, "Exploitation of Track Accuracy Information in fusion Technologies for Radar Target Classification using Dempster-Shafer Rules", *12th International Conference on Information Fusion Seattle, WA, USA*, (July 6-9 2009).
29. L. Jang, J. Chao, "An information fusion algorithm for data association in multi target tracking", *Data Fusion Symposium, Adelaide, SA, Australia*, (21-22 Nov 1996).
30. Bar-Shalom. Y, Xiao-Rong. L, "Estimation and Tracking: Principles Techniques and Software", *Norwood, MA: Artech House*, (1993).
31. Y. Bar-Shalom, T. E. Fortmann, "Tracking and Data Association", *Academic Press*, (1988).
32. Y. Bar-Shalom, D.B. Blair, "Multitarget-multisensr tracking: applications and advances", V.3, *Artech House*, (2000).
33. Maria Isabel Ribeiro, "Kalman and Extended Kalman Filters Concept Derivation and Properties", *Institute Systems and Robotics*, (February 2004).
34. A. Farina, P. Lombardo, M. Marsella, "Joint tracking and identification algorithms for multisensor data", *Navigation review*, vol.149, issue.6, (December 2002), 271-280.
35. P. Braca, M. Guerriero, S. Marano, V. Matta, P. Willett, "Distributed Estimation with Data Association: Is the Nearest Neighbor The Most Informative?" *12th*

- International Conference on Information Fusion Seattle, WA, USA, (July 6-9 2009).
36. S. Blackman, "Multiple-Target Tracking with Radar Applications", Artech House, (1986).
 37. R.J. Fitzgerald, "Development of practical PDA logic for multitarget tracking by microprocessor", In Proceedings of the American Control Conference, Seattle, Washington-USA, (18-20 June 1986) , 889 - 898.
 38. Ward K. D, "Compound representation of high resolution sea clutter", Electronics Letters, V.17, (1981), 561-563.
 39. Emmanuelle JAY, "Détection en environnement non-Gaussien", Thèse de Doctorat, Université de Cergy-Pontoise, (Juin 2002).
 40. J.R. Hoffman, R.P.S. Mahler, "Multitarget miss distance and its applications", In Proceedings of the Fifth International Conference on Information Fusion, V.1, (2002), 149–155.
 41. S. Challa, G.W. Pulford, "Joint Target Tracking and Classification Using Radar and ESM Sensors" Aerospace and Electronic Systems, V. 37, issue .3, (July 2001), 1039-1055.
 42. A.P. Blom Henk, Y. Bar-Shalom, "The interacting multiple model Algorithm for systems with Markovian Switching Coefficients", IEEE Transaction on Automatic Control, V.3, issue. 8, (August 1988), 780-783.
 43. Y.T. Chan, F. Couture, "Manoeuvre detection and track correction by input estimation", Navigation reviews, V. 140, n°.1, (1993), 21-28.
 44. Y. Bar-Shalom, Blom, Henk A.P, "The Interacting Multiple Model Algorithm for Systems with Markovian Switching Coefficients", IEEE Transactions on Automatic Control, V.33, (August 1988), 780–783.
 45. Ryan R. Pitre, Vesselin P. Jilkov, X. Rong Li, "A comparative study of multiple-model algorithms for maneuvering target tracking", Department of Electrical Engineering, University of New Orleans, (04-2001).
 46. Schleher D. C, "Radar detection in Weibull clutter" IEEE Transactions on Aerospace and Electronic Systems, V.12, n°6, (1976) , 736-743.
 47. Goldstein G. B, "False alarm regulation in log-normal and weibull clutter", Transactions on Aerospace and Electronic Systems, V. 9, n°1, (1973), 84-92.

48. Sayama. S, Sekine. M, "Weibull distribution and K-distribution of sea clutter observed by X-band radar and analyzed by AIC", IEICE Transactions on Communication, V. 83, n°9, (September 2000), 1978-1982.
49. Y. Bar-Shalom, X.R.Li, T. Kirubarajan, "Estimation with Applications to Tracking and Navigation", John Wiley & Sons, New York, (2001).
50. Messaoudi. Z, Oussalah. M, Ouldali. A, "Multiple Target Tracking Using Cheap Joint Probabilistic Data association Multiple Data Association Particle Filter in Sensors Array", International Journal of Artificial Intelligence & Applications (IJAIA), V.3, n°4, (July 2012).