

**UNIVERSITE DE SAAD DAHLEB DE BLIDA**

**Faculté des Sciences de l'Ingénieur  
Département d'Aéronautique**

**MEMOIRE DE MAGISTER**

(en Aéronautique)  
Spécialité : Aéronautique

**ALGORITHME DES MESURES HORS SEQUENCE  
(OOSM) : APPLICATION A LA POURSUITE DE CIBLES  
MANOEUVRANTES**

Par

**AMROUCHE Naima**

Devant le jury composé de :

A. GUESSOUM	Professeur, U.S.D.B	Président
D. BERKANI	Professeur, ENP	Rapporteur
L. BOUNATIRO	Maitre de Conférences, U.S.D.B	Examineur
M. DJENDI	Maitre de Conférences, U.S.D.B	Examineur
S. MEGUELATI	Chargé de Cours, U.S.D.B	Co-rapporteur

Blida, Février 2009

## ملخص

في هذه المذكرة نقوم بوصف نظام المتابعة المتعدد أجهزة الالتقاط المعتمد على ترشيح (IB1) OOSM وهي تقنية القياسات الخارجة عن النظام. نبدأ بتقويم بعض المعلومات العامة على متابعة الأهداف أيضا الترشيحات المستعملة في هذه الأخيرة ثم نقوم بوصف أطراف الأنظمة المتعددة المتواجدة لتقدير الحركة. و قد ركزنا وصفنا على خوارزميات (BI1) OOSM وخوارزمية OOSM-MMI (MMI-IB1) التي بإمكانها تقدير المعايير الحركية للهدف المتحرك في حالة وصول قياسات أحد أجهزة الالتقاط متأخرة إلى مركز المتابعة (المعالجة).

وأخيرا نقوم بتقديم نتائج تجريبية تدل على فعالية هذه الخوارزمية.

### كلمات مفتاحيه:

متابعة الأهداف ، خوارزمية القياسات الخارجة عن النظام ، خوارزمية الأنظمة المتعددة، نظام المتابعة المتعدد أجهزة الالتقاط المعتمد ، تنبؤ.

## RESUME

Dans ce mémoire, nous décrivons une technique de poursuite multicapteur basée sur le filtrage OOSM, c'est la technique des mesures hors séquence. Nous commençons par introduire quelques généralités sur la poursuite de cibles, ainsi que les filtres utilisés dans cette dernière. Puis nous décrivons les différentes approches à modèles multiples existantes pour l'estimation du mouvement, nous avons basé notre description sur les algorithmes OOSM (B11) et l'algorithme IMM-B11 un algorithme capable d'estimer les paramètres dynamiques de la cible manœuvrante en cas de retard des mesures d'un capteur au centre de traitement.

Enfin, nous présentons les résultats expérimentaux qui indiquent une certaine efficacité de l'algorithme.

### Les mots clés:

Mesures hors séquence, Poursuite multi capteurs, Poursuite de cible, Filtrage, Approche à modèles multiples, Prédiction.

## **ABSTRACT**

In this memory, we describe a technique of multi-sensor tracking based on OOSM filtering; it is the out of sequence measurements technique. We start by introducing some general information on the target tracking, as well as the filters used in the latter. Then we describe the different multiple models approach existing for the estimate of the movement, we based our description on algorithms OOSM (B11) and the IMM-B11 algorithm, an algorithm able to estimate the dynamic parameters of the manoeuvring target in the event of delay of sensor measurements in the central tracker.

Finally we have the experimental results which indicate a certain effectiveness of the algorithm.

### Keywords:

Out Of Sequence measurements, Multi sensor target tracking, target tracking, filtering, multiple models approach, Prediction.

## REMERCIEMENTS

Je remercie d'abord DIEU qui a permis la réalisation de ce manuscrit.

Je tiens à remercier Monsieur Daoud BERKANI Professeur de l'Ecole National Polytechnique, qui ma fait l'honneur d'être mon directeur de thèse.

J'aimerais bien souligner que ce mémoire n'aurait jamais existé sans mon enseignant et mon co-promoteur Monsieur Smaine MEGUELATI je le remercie beaucoup pour son aide par ses orientations et son suivi attentif au long de ce travail.

J'adresse mes vifs remerciements au Lieutenant Colonel M.S DJOUADI (Chef de laboratoire Robotique et Production de l'Ecole Militaire Polytechnique) pour son aide le long de ce travail aussi bien que sa gentillesse.

Je remercie Monsieur Abed Rezzak GUESSOUM, Professeur au département d'Electronique de U.S.D de Blida, d'avoir accepté de présider le Jury.

Je remercie Monsieur Loth BOUNATIRO, maitre de conférences au département d'Aéronautique de U.S.D de Blida, d'avoir accepté de faire partie du jury.

Je remercie Monsieur Mohamed DJENDI, maitre de conférences au département d'Electronique de U.S.D de Blida d'avoir accepté de faire partie du jury.

Je tiens ensuite à remercier tout spécialement Lieutenant Yacine MORSLY pour son aide.

Je remercie aussi Mr Mohamed Sahmoudi, Ph.D. Researcher Associate at LACIME Department of Electrical Engineering, Ecole de Technologie Supérieure (ETS), Montréal, Québec, Canada.

Je remercie également Mr Abde Rezzak Benaskeur, Ph.D. à la recherche et développement pour la défense Canada – Valcartier.

Je tien également à remercier tous les membres du laboratoire Robotique et Production, de l'Ecole Militaire Polytechnique.

Mes remerciements s'adressent également à mes enseignants de DAB.

Evidemment, je remercie chaleureusement toute ma famille.

Merci à tous mes amis.

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

# TABLE DES MATIERES

RESUMES.....	
REMERCIEMENTS.....	
TABLE DES MATIERES.....	
LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX.....	
INTRODUCTION.....	13
1. GENERALITES SUR LA POURSUITE DES CIBLES.....	16
1.1 Introduction.....	16
1.2 Le suivi des obstacles.....	17
1.3 Les capteurs.....	18
1.4 La télémétrie laser.....	19
1.5 Le radar.....	21
1.5.1 Radar de poursuite.....	22
1.5.2 Radars aéroportés.....	23
1.6 Classification des systèmes capteurs.....	26
1.6.1 Les systèmes à capteur unique.....	26
1.6.2 Les systèmes multi-capteurs.....	27
1.7 Le problème des mesures hors séquence (OOSM).....	30
1.8 Types de cibles.....	32
1.8.1 Cibles non manœuvrantes.....	32
1.8.2 Cibles manœuvrantes.....	33
1.9 Détecteur de manœuvre.....	33
1.9.1 Techniques de détection de manœuvres.....	34
1.9.2 Techniques basées sur l'estimation de l'accélération.....	36
1.10 Adaptation à la manœuvre.....	37
1.10.1 Approche basée sur le changement des paramètres de poursuite.....	37
1.10.2 Approche basée sur le changement de la dimension du modèle.....	38
1.10.3 Approche basée sur l'estimation de l'accélération.....	39
1.10.4 Approche à Modèles Multiples.....	39

1.11 Conclusion .....	41
2. LE FILRAGE DE KALMAN .....	42
2.1 Introduction .....	42
2.2 Les applications du filtre .....	42
2.3 Le filtre de Kalman discret .....	43
2.3.1 Le processus d'estimation .....	43
2.3.2 Les origines de calcul du filtre .....	44
2.3.3 Les origines probabilistes du filtre.....	46
2.3.4 L'algorithme du filtre de Kalman discret.....	47
2.3.5 Les paramètres et le réglage du filtre .....	49
2.4 Le filtre de Kalman étendu (EKF) :.....	50
2.5 Initialisation du filtre .....	55
2.6 Modèles d'état.....	56
2.6.1 Modèle à vitesse constante (CV).....	56
2.6.2 Modèle à accélération constante (CA).....	57
2.6.3 Modèle de virage (CT) .....	58
2.7 Conclusion .....	59
3. APPROCHES A MODELES MULTIPLES POUR L'ESTIMATION DU MOUVEMENT .....	60
3.1 Introduction .....	60
3.2 Estimation adaptative à modèles multiples .....	60
3.3 Approches d'estimation à modèles multiple pour la poursuite de cibles .....	61
3.3.1 Approche à modèles multiples (cas de non changement de modèles).....	61
3.3.2 Approche à modèles multiples (cas de changement de modèle) .....	63
3.4 Conclusion .....	70
4. LES MESURES HORS SEQUENCE.....	71
4.1 Introduction .....	71
4.2 Les origines des mesures hors séquence (OOSM) .....	71
4.3 Principe de traitement des mesures hors séquence .....	73
4.4 OOSM à un pas de retard.....	76
4.4.1 Formulation du problème.....	77
4.4.2 Algorithme optimal A1.....	80
4.4.3 Algorithme sous-optimal B1.....	82
4.5 OOSM à l pas de retard .....	83



4.5.1	Formulation du problème.....	83
4.5.2	L'approche de résolution du problème.....	84
4.5.3	L'algorithme sous optimal BL1.....	86
4.6	L'Algorithme IMM-OOSM pour cible manœuvrante.....	88
4.7	Conclusion.....	92
5.	SIMULATION ET COMMENTAIRES.....	93
5.1	Introduction.....	93
5.2	L'objet de la simulation.....	93
5.3	Simulation de l'algorithme OOSM (BL1).....	93
5.3.1	Génération de trajectoire rectiligne.....	93
5.3.2	L'organigramme général de l'algorithme BL1 (OOSM).....	94
5.3.3	Résultats de simulation OOSM (BL1) la trajectoire rectiligne.....	96
5.3.4	Interprétation des résultats.....	98
5.4	Simulation de l'algorithme IMM-OOSM (IMM-BL1).....	100
5.4.1	Génération de la trajectoire à virage.....	100
5.4.2	Organigramme général de l'algorithme IMM-OOSM.....	101
5.4.3	Présentation générales de l'interface (IMM-OOSM).....	103
5.4.4	Résultats de simulations.....	104
5.4.5	Interprétation des résultats.....	116
5.5	Conclusion :.....	118
	CONCLUSION.....	119
	APPENDICE.....	
	A. Liste des symboles et des abréviations.....	
	REFERENCES.....	

## LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX

Figure 1.1 : Structure haut niveau d'un système de surveillance.....	17
Figure 1.2 : Le module de pistage.....	18
Figure 1.3 : Principe de mesure de distance.....	20
Figure 1.4 : Structure d'un radar à antenne.....	22
Figure 1.5 : Principe des radars aéroportés.....	24
Figure 1.6 : Les applications des radars de veille.....	24
Figure 1.7 : Schéma d'un module de pistage de cibles à capteur unique.....	26
Figure 1.8 : Schéma d'un module de pistage de cibles à capteur unique.....	27
Figure 1.9 : Architecture multi-plateformes centralisée.....	28
Figure 1.10 : Schéma d'un système multi-capteurs centralisés.....	29
Figure 1.11 : Schéma d'un système multi-capteurs décentralisés.....	29
Figure 1.12 : Capteur de fusion système.....	30
Figure 1.13 : L'origine des mesures hors séquence (OOSM).....	31
Figure 1.14 : Cibles (a) non manœuvrantes (b) manœuvrantes.....	32
Figure 1.15 : Processus de filtrage en présence d'un détecteur de manœuvre....	34
Figure 1.16 : Adaptation des dimensions de la fenêtre de corrélation.....	38
Figure 1.17 : Filtrage avec changement de la dimension du filtre.....	39
Figure 1.18 : Schéma bloc d'un système MM.....	40
Figure 1.19 : Schéma bloc du système à Modèles Multiples Interactifs (IMM).....	41
Figure 2.1 : Interprétation du filtre de Kalman.....	46
Figure 2.2 : Le cycle du filtre de Kalman discret.....	47
Figure 2.3 : Schéma de l'algorithme du filtre de Kalman.....	49
Figure 2.4 : Schéma de l'algorithme du filtre de Kalman étendu.....	54
Figure 3.1 : Schéma fonctionnel de l'algorithme d'estimation à modèles multiples fixes cas de non changement de modèles).....	62
Figure 3.2 : Schéma descriptif de l'algorithme GPB-1.....	64
Figure 3.3 : Schéma descriptif de l'algorithme GPB-2.....	65

Figure 3.4 : Schéma descriptif de l'algorithme IMM.....	67
Figure 4.1 : L'architecture de poursuite multicapteurs.....	72
Figure 4.2 : poursuite mono-cible multi-capteurs.....	73
Figure 4.3 : Poursuite multi-cibles multi-capteurs.....	73
Figure 4.4 : Deux scénarios de fusion centralisée en cas de production de phénomène OOS (Out Of Séquence).....	74
Figure 4.5 : Le filtrage OOS séquentiel.....	75
Figure 4.6 : Le filtrage OOS non séquentiel.....	76
Figure 4.7 : OOSM à un pas de retard.....	77
Figure 4.8 : OOSM à l pas de retard ( $l=2$ ).....	83
Figure 4.9 : Le cycle de l'algorithme BL1.....	87
Figure 4.10 : l'intégration de l'OOSM dans l'IMM.....	89
Figure 5.1 : Génération de la trajectoire rectiligne.....	94
Figure 5.2 : Organigramme de l'algorithme OOSM (BL1).....	95
Figure 5.3 : Poursuite de la trajectoire selon KF (capteur 1, en séquence) et OOSM (BL1) (scénario 1) ( $L=1$ ).....	96
Figure 5.4 : Erreurs de position selon KF (capteur 1, en séquence) et l'OOSM (BL1) (scénario 1) ( $L=1$ ).....	97
Figure 5.5 : Erreurs de position selon l'OOSM (BL1) et les positions mesurées (scénario 1) ( $L=2$ ).....	97
Figure 5.6 : Poursuite de la trajectoire selon KF (capteur 1, en séquence) et OOSM (BL1) ( $L=2$ ).....	98
Figure 5.7 : Erreurs de position selon KF (capteur 1, en séquence) et l'OOSM (BL1) ( $L=2$ ).....	98
Figure 5.8 : Erreurs de position selon l'OOSM (BL1) et les positions mesurées (scénario 1) ( $L=2$ ).....	98
Figure 5.9 : Génération de la trajectoire à deux tronçons.....	100
Figure 5.10 : Organigramme de l'algorithme IMM-OOSM.....	102
Figure 5.11 : L'interface.....	103
Figure 5.12 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 2) ( $L=1$ ).....	106
Figure 5.13 : Estimation de la vitesse selon l'IMM seul (radar 1, en séquence) et l'IMM-OOSM (scénario 2) ( $L=1$ ).....	107

Figure 5.14 : Erreurs de position selon IMM seul (capteur 1, en séquence) et l'IMM-OOSM (scénario 2) (L=1).....	107
Figure 5.15 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 2) (L=1).....	107
Figure 5.16 : Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=1).....	108
Figure 5.17 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=1).....	108
Figure 5.18 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=1).....	108
Figure 5.19 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 2) (L=2).....	109
Figure 5.20 : Estimation de la vitesse selon l'IMM seul (radar 1, en séquence) et l'IMM-OOSM (scénario 2) (L=2).....	109
Figure 5.21 : Erreurs de position selon IMM seul (capteur 1, en séquence) et l'IMM-OOSM (scénario 2) (L=2).....	109
Figure 5.22 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 2) (L=2).....	110
Figure 5.23 : Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=2).....	110
Figure 5.24 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=2).....	110
Figure 5.25 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=2).....	111
Figure 5.26 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) (L=1).....	111
Figure 5.27 : Estimation de la vitesse selon l'IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) (L=1).....	112
Figure 5.28 : Erreurs de position selon IMM seul (radar 1, en séquence) et IMM-OOSM (scénario 3) (L=1).....	112
Figure 5.29 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 3) (L=1).....	113
Figure 5.30 : Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et	

IMM-OOSM (scénario 3) (L=1).....	113
Figure 5.31 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=1).....	113
Figure 5.32 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=1).....	113
Figure 5.33 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) (L=2).....	114
Figure 5.34 : Estimation de la vitesse selon l'IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) (L=2).....	114
Figure 5.35 : Erreurs de position selon IMM seul (radar 1, en séquence) et IMM-OOSM (scénario 3) (L=2).....	114
Figure 5.36 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 3) (L=2).....	115
Figure 5.37 : Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=2).....	115
Figure 5.38 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=2).....	115
Figure 5.39 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=2).....	116
Tableau 5.1 : La moyenne des erreurs de position (radar 1, en séquence et OOSM (scénario 1).....	99
Tableau 5.2 : La moyenne des erreurs de position (radar1, en séquence) et IMM-OOSM (scénario 2).....	117
Tableau 5.3 : La moyenne des erreurs de position (radar1, en séquence) et IMM-OOSM (scénario 3).....	117
Tableau 5.4 : le temps d'arrivées des mesures des différents pas de retard.....	118

## INTRODUCTION

La prolifération et le développement sans cesse grandissant des systèmes de surveillance, que ce soit militaire ou civile, a engendré l'engouement des chercheurs pour des algorithmes de poursuite capables de traquer les cibles manoeuvrantes et non manoeuvrantes, en utilisant comme mesures et des données pouvant provenir d'un ou de plusieurs capteurs de même ou de différents types.

La fonction pistage constitue le noyau algorithmique des applications de surveillance, tant civiles (contrôle du trafic aérien, ...) que militaires (défense aérienne, système d'armes, ...), où elle permet de convertir l'information extraite des capteurs en une information spatio-temporelle de plus haut niveau (chaîne détection-pistage-classification d'un radar par exemple). Les techniques à mettre en œuvre pour réaliser cette fonction, font généralement appel au filtrage de Kalman et présentent aujourd'hui une réelle maturité, même si de nombreuses applications opérationnelles continuent à utiliser d'anciennes solutions moins performantes. Toutefois deux facteurs récents méritent une attention particulière :

- Evolution des objets à pister: mobilité accrue, détection plus difficile, en particulier bien sûr, dans le domaine militaire avec par exemple le cas des avions à forte manoeuvrabilité et à structures furtives.
- Evolution des systèmes de mesures: progrès des radars, apparition des capteurs imageurs, systèmes multicapteurs.

La manoeuvrabilité accrue des mobiles constitue une première cause d'évolution des algorithmes de pistage. Alors que la solution de base (filtrage de Kalman) ne permet pas de modéliser l'apparition des manoeuvres, de nombreux travaux ont visé la modification de cette dernière pour la rendre adaptative.

Un tel intérêt pour la poursuite de cibles est dû au fait que celle-ci trouve son application dans des domaines technologiques aussi nombreux que variés et peuvent être à caractère civile ou militaire et les deux à la fois (problèmes duaux). En effet, à titre d'exemple nous pouvons citer :

- La poursuite de cibles multicateurs (cibles terrestres ou volantes);
- La poursuite d'une ou plusieurs cibles volantes (notamment ennemis) est plus que stratégique pour la défense aérienne ;
- La poursuite de cible permet de contrôler la fluidité du trafic, la détection des excès de vitesse ainsi que les dépassements dangereux ;
- Pour la protection et la surveillance des bâtiments sensibles, la poursuite constitue une partie importante des systèmes de surveillance visuelle ;
- .....

Ce n'est qu'en 1964 qu'il a été mis en évidence, que lors de la poursuite de cibles il peut y avoir des incertitudes associées avec les mesures, en plus des erreurs qui les entachent, qui sont généralement modélisés par un bruit additif. Cette incertitude additionnelle est relative à l'origine des mesures, cette dernière qui ce doit être utilisée dans un algorithme de poursuite, peut ne pas provenir de la cible qui fait l'objet d'intérêt. Cette situation peut se produire dans un système de surveillance fonctionne en présence de bruits, contre mesures, ou fausse alarmes.

Le problème du pistage des cibles (non manœuvrante et manœuvrante) multicateur, est que les mesures de la même cible peuvent arriver au centre de traitement de façon désordonné ou hors séquence à cause du réseau de communication. Ce problème est désigné sous le nom de Mesures Hors Séquence (MHS), tiré de l'anglais "Out-Of-Séquence Measurements" (OOSMs). Il est très connue dans le domaine militaire lors de la surveillance des champs de bataille, où un traqueur central (centre de traitement) reçoit les mesures en temps réel.

Ce problème a poussé les spécialistes du domaine de pistage et de la poursuite à corriger les erreurs de la mesure avec un algorithme qui fait la mise a

jour des mesures actuelles en se basant sur l'estimation des mesures reçues précédemment.

C'est dans le cadre de cette dernière problématique que s'inscrit le présent travail. En effet, l'objectif de ce mémoire est d'apporter une contribution pour la résolution du problème des mesures hors séquence, afin de permettre une poursuite efficace et efficiente au centre de traitement d'une cible (non manoeuvrante, manoeuvrante) poursuivie par plusieurs capteurs.

Pour une meilleure présentation des dits travaux, ce présent mémoire est scindé en cinq chapitres qui peuvent être résumés comme suit :

Le premier chapitre est consacré à la présentation des généralités sur la poursuite des cibles.

Le second chapitre élabore la formulation du filtre de Kalman ainsi que une étude très détaillée sur ses différents paramètres qui seront utilisés dans la poursuite.

Le troisième chapitre comprend une étude sur les différentes approches à modèles multiples et précisément une étude détaillée de l'algorithme Modèle Multiple Interagissant (IMM).

Dans le quatrième chapitre nous nous sommes intéressés de près aux notions de mesures hors séquence, et de détaillé les algorithmes OOSM (out of séquence measurements) utilisés au cas de la poursuite de cibles non manoeuvrantes puis manoeuvrantes.

Nous terminerons par un cinquième chapitre dédié à la présentation de notre travail. En effet au niveau de ce chapitre nous présentons les résultats de toutes les simulations que nous avons effectuées avec les algorithmes OOSM, et les différents commentaires concernant les performances de ces algorithmes.

Enfin ce mémoire se termine par une conclusion générale situant le travail accompli et proposant quelques perspectives à donner à ce travail.



# 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 l'orientation des vents).

## 1.2 Le suivi des obstacles

Le rôle du pistage de cible est avant tout d'assurer la cohérence temporelle des observations afin d'éviter les fausses alarmes et de filtrer l'état. La structure haute niveau d'un tel système est donnée par la figure (1.1). Les capteurs délivrent des signaux qui sont collectés par un module de traitement du signal délivrant des mesures au 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 [11].

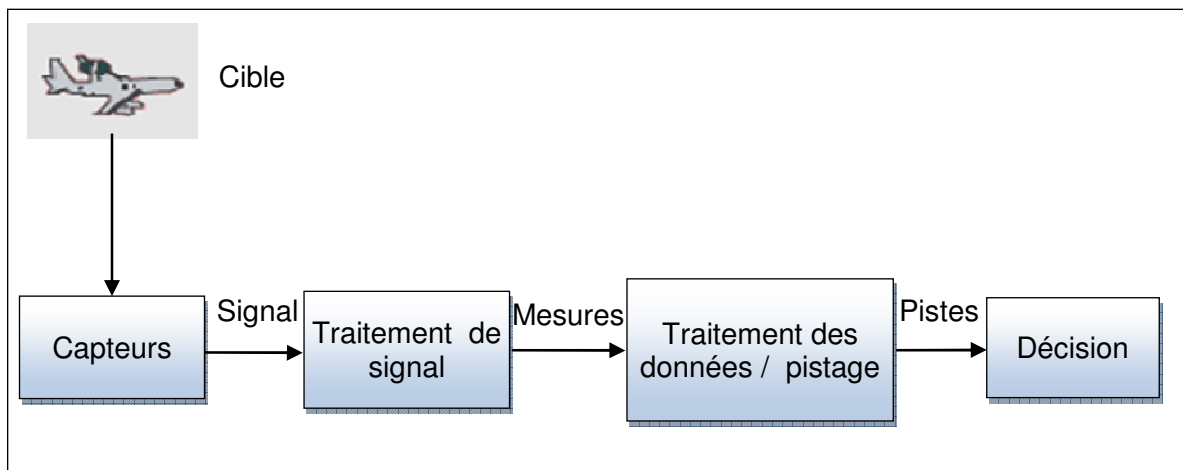


Figure 1.1 : Structure haut niveau d'un système de surveillance

Le suivi d'obstacles est un élément indispensable pour un système de détection d'obstacles. Son rôle est de déterminer le nombre, la position, et le mouvement des différentes pistes. 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, voir accélération). Ce module s'appuie sur une méthode de filtrage telle que le filtrage de Kalman ou le filtrage particulaire. D'autres modules comme l'initialisation, la destruction, l'association des pistes sont indispensables au bon fonctionnement (voir figure 1.2).

En effet toutes les mesures délivrées par les capteurs ne sont pas forcément des mesures d'obstacles mais peuvent provenir d'interférences

aléatoires (conditions atmosphériques, fausses alarmes,...). Il est donc nécessaire de valider les mesures qui correspondent le mieux à l'estimation : c'est l'association [11].

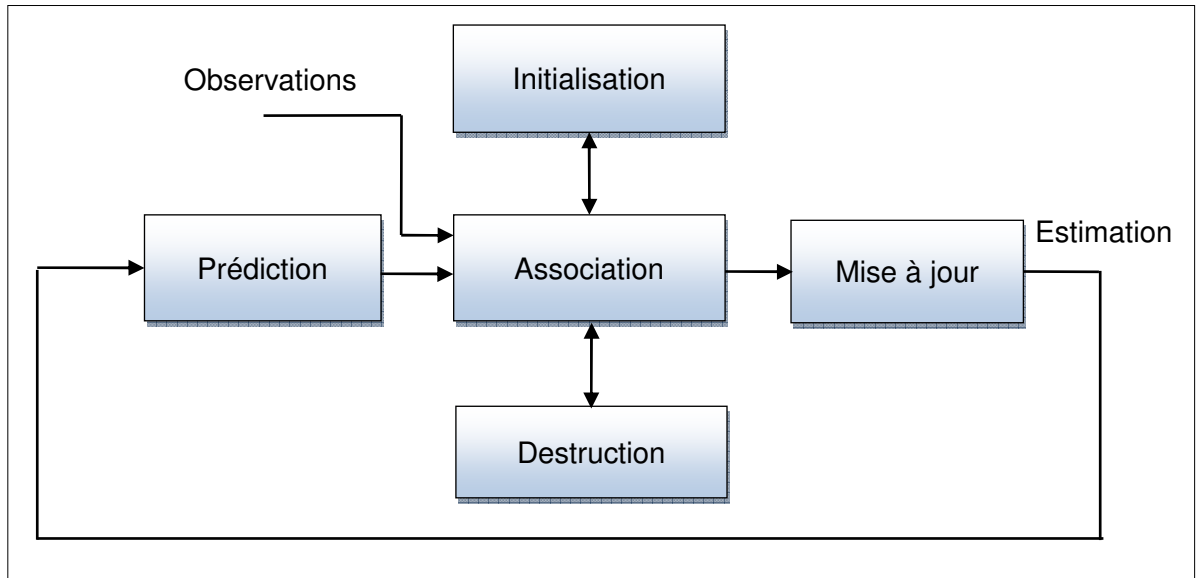


Figure 1.2 : Le module de pistage

Une piste tentée est typiquement issue d'une mesure non associée avec les pistes existantes. La confirmation d'une piste est basée sur le nombre de mises à jour effectuées 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 Les capteurs

La détection d'obstacles est un des problèmes clefs de la poursuite des cibles manœuvrantes. Chaque cible devant évoluer dans un environnement inconnu, doit être capable de détecter les obstacles.

Selon J. Hancock, la détection d'obstacles ne sera jamais un problème résolu. En effet, les cibles manœuvrantes deviennent de plus en plus capables et évoluent à des vitesses qui ne cessent d'augmenter; ces cibles auront donc besoin d'observer plus loin, d'examiner de plus larges zones et nécessiteront des laps de temps de plus en plus court.

De plus, la population apparaissant de plus en plus dépendante de ces systèmes, il paraît nécessaire de faire accroître leur fiabilité.

Du côté des aéronefs, plus les systèmes sont devenus capables, plus l'attention s'est focalisée sur le problème de la détection d'obstacles. Ces systèmes résultent pour la plupart de collaborations nombreuses et de qualité.

Précédemment, on a dit que les aéronefs utilisaient de nombreux capteurs. En effet, un espace aérien est une scène complexe à analyser, dépendante de nombreuses circonstances (météo, vitesse,...). Les différents capteurs présentés dans la suite apportent leurs solutions à ces problèmes de perception. Chaque capteur peut résoudre une tâche spécifique. Les télémètres Laser et Radar sont particulièrement adaptés pour la détection d'obstacles. De l'autre côté, les caméras permettent d'effectuer toutes les tâches de perception (reconstruction et reconnaissance de la piste, de la signalisation, la localisation de la cible, détection d'obstacles). Cependant, leurs performances sont souvent limitées ou restreintes par les conditions expérimentales (météo, lumière, ...).

On s'attache donc ici à présenter les capteurs utiles pour la détection d'obstacles. On s'intéressera particulièrement aux capteurs utilisés pour valider les méthodes développées.

#### 1.4 La télémétrie laser

Depuis de nombreuses années, la télémétrie laser est utilisée pour la détection d'obstacles, spécialement pour la navigation en terrain inconnu. La télémétrie laser opère par balayage d'un faisceau dans une région d'intérêt et mesure, pour chaque pixel, le temps mis par le faisceau laser pour partir et revenir au capteur. De plus, connaissant la position angulaire du tir, on peut en déduire la position exacte de l'objet dans un plan. Enfin, aujourd'hui, la plupart des télémètres lasers renvoient l'intensité du signal pour chaque pixel en mesurant l'énergie du signal laser retourné. Donc, un balayage complet en deux dimensions peut donner une image de profondeur et une image d'intensité. Les obstacles peuvent donc être détectés en observant les discontinuités apparaissant dans l'image de profondeur et dans l'image d'intensité [11].

### ■ Le télémètre Laser 3D

Le télémètre Laser est un système capable de délivrer des images 3D. Ces images sont basées sur la mesure de distance précise délivrée par un système opto-électronique et sur un mécanisme à double balayage. Elles sont formées en exécutant une série de mesure de distance dans des positions différentes, avec des directions angulaires bien définies. Ces données de distance associées aux angles forment la base des images 3D.

Ces images 3D ou de profondeur se présentent sous la forme de matrice par analogie avec les images de luminance.

Chaque élément de la matrice représenté un pixel. Chaque pixel donne une information sur la scène observée par le capteur 3D. Cette information représenté une indication de position dans la scène. En résumé, l'information contenue par chaque pixel de l'image de profondeur représenté les coordonnées géométriques de celui-ci dans le repère du capteur [11].

### ■ Le module de mesure de distance

Le système de mesure de distance est basé sur le principe du calcul de temps de vol des impulsions laser de longueur d'onde dans le proche infra-rouge.

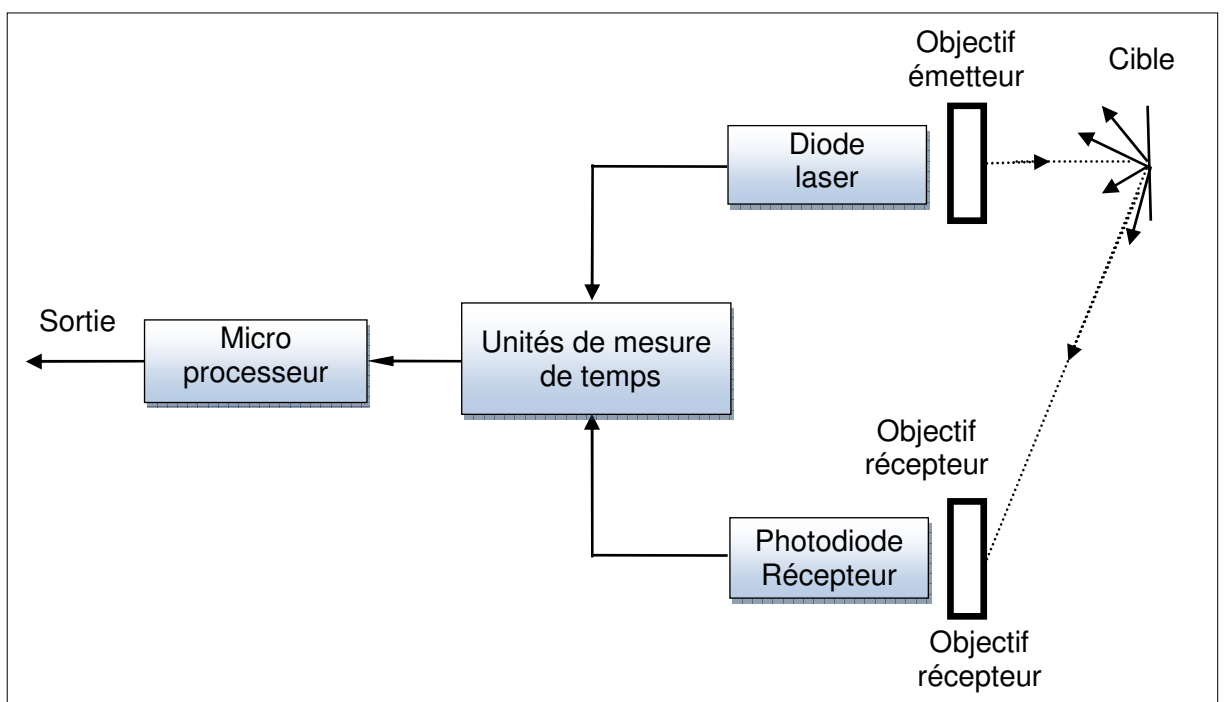


Figure 1.3 : Principe de mesure de distance

Un générateur d'impulsions électriques commande une diode laser semi-conductrice qui envoie des impulsions de lumière infrarouge vers un objectif émetteur. A travers l'objectif récepteur, une partie du signal réfléchi par une cible frappe une photo diode, ce qui génère un signal électrique. L'intervalle de temps entre l'émission et la réception est mesuré au moyen d'une fréquence d'horloge stabilisée par un quartz. La mesure de distance calculée est transmise à un microprocesseur interne qui prépare les données à transmettre au PC (voir figure 1.3) [11].

### 1.5 Le radar

Fondamentalement, un radar doit permettre de détecter l'obstacle mobile ou non et de calculer la distance le séparant de la cible. Dans cette optique, les radars à ondes hyperfréquences peuvent être divisés en deux grandes catégories : les radars impulsionnels d'une part, les radars à émission continue et à modulation de fréquence d'autre part.

Pour les radars impulsionnels, on s'attache à déterminer le temps écoulé entre, l'écho provenant de l'obstacle détecté et le signal émis. On peut à nouveau distinguer deux familles, selon que la détection du signal réfléchi par l'obstacle est cohérente ou non. Les modèles à détection non cohérente sont les plus simples à réaliser, mais ne permettent pas d'évaluer la vitesse de la cible (pas de mesure de phase), et ne permettent donc pas de développer tous les types d'applications désirés. Le second type (à détection cohérente) résout ce problème en permettant d'avoir une relation entre la phase du signal émis et celle du signal réfléchi par la cible. Pour les radars à émission continue et à modulation de fréquence, il s'agit de déterminer le décalage en fréquence entre l'écho provenant de l'obstacle détecté et le signal émis. Le radar est alors structuré autour d'un oscillateur contrôlé en tension, qui sert tant en émission qu'en réception. Il permet en effet à la fois de transmettre le signal à l'antenne en assurant un bon contrôle de la fréquence, et de passer en fréquence intermédiaire le signal reçu. La spécificité du récepteur est donc que son fonctionnement n'est basé que sur un multiplieur. Le signal en fréquence intermédiaire étant ensuite simplement amplifié, et transféré à une unité de traitement [11].

Cette simplification de la partie hyperfréquence entraîne donc un accroissement de la partie de traitement du signal en réception, mais ceci va de pair avec l'évolution des performances des dispositifs de traitement. De fréquence, il s'agit de déterminer le décalage en fréquence entre l'écho provenant de l'obstacle détecté et le signal émis. Le radar est alors structuré autour d'un oscillateur contrôlé en tension, qui sert tant en émission qu'en réception. Il permet en effet à la fois de transmettre le signal à l'antenne en assurant un bon contrôle de la fréquence, et de passer en fréquence intermédiaire le signal reçu. La spécificité du récepteur est donc que son fonctionnement n'est basé que sur un multiplieur.

Cette simplification de la partie hyperfréquence entraîne donc un accroissement de la partie de traitement du signal en réception, mais ceci va de pair avec l'évolution des performances des dispositifs de traitement [11].

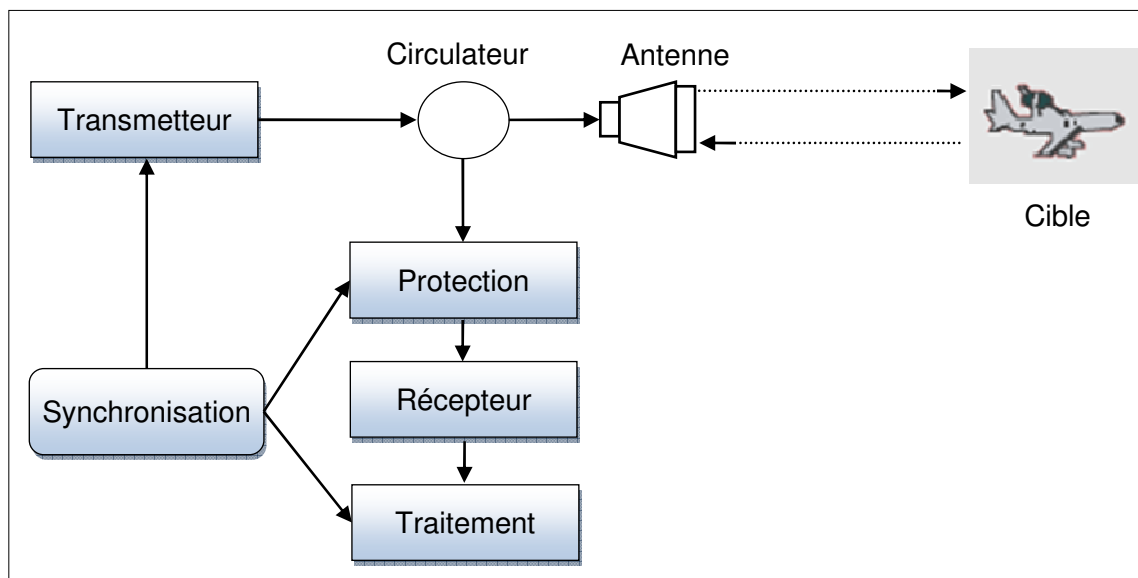


Figure 1.4 : Structure d'un radar à antenne

### 1.5.1 Radar de poursuite

Un radar de poursuite mesure les coordonnées d'une cible et délivre les informations qui sont utilisées pour déterminer sa trajectoire et au besoin prédire sa position future. Tout ou partie des coordonnées utilisables : distance, site, azimut, fréquence Doppler sont mesurées à cet effet. Presque tous les radars peuvent être considérés comme des radars de poursuite si les informations qu'ils

délivrent sont traitées afin d'établissement de pistes. On désigne néanmoins sous le nom de radars de poursuite ceux qui peuvent effectuer cette opération en temps réel et avec une précision suffisante, ce qui, comme nous le verrons par la suite entraîne des procédés particuliers de mesure tant des angles que de la distance (ou de la fréquence Doppler). Les radars de poursuite eux-mêmes se divisent en deux catégories :

- les radars de poursuite continue, qui mesurent sans interruption les coordonnées d'une cible (ou d'un faible nombre) placée dans le champ de leur antenne [20].
- les radars de poursuite discontinue (Track - While - Scan) dont les propriétés d'agilité permettent la poursuite simultanée de plusieurs cibles situées dans un domaine d'action relativement étendu. Les informations de trajectoire sont alors obtenues séquentiellement sur chaque cible, au moyen d'une poursuite limitée à des fractions de trajectoire de chacune d'elles [20].

La principale utilisation des radars de poursuite continue est le contrôle des trajectoires d'engins, allant de l'engin sol-air ou air-air d'interception, aux lanceurs de missiles ou de satellites, et la détermination des trajectoires d'avions, de missiles, de satellites dans des buts divers (interception, alerte, établissement d'éphémérides) [20].

### 1.5.2 Radars aéroportés

Les radars aéroportés se distinguent des radars de surface par le fait qu'ils constituent des observatoires élevés, propres à la détection à grande distance des cibles de surface ou évoluant à très basse altitude. En contrepartie, ils sont beaucoup plus perturbés par les échos de sol du fait qu'ils regardent souvent vers le bas et qu'ils sont eux-mêmes mobiles; dans beaucoup de cas, la détection des cibles utiles exigera un filtrage Doppler pour distinguer les cibles mobiles dans les échos fixes [20].






Figure 1.5 : Principe des radars aéroportés

Enfin, leur situation particulière les amènera à être utilisés dans des fonctions particulières comme la navigation, la cartographie et la reconnaissance [20].

#### ■ Radars de veille aéroportés

Les radars de veille aéroportés sont spécialement utilisés pour la surveillance des aéronefs évoluant à basse altitude, mais aussi des véhicules terrestres et maritimes (fig. 1.6).

On peut les décomposer en trois catégories :




Figure 1.6 : Les applications des radars de veille

➤ les radars de surveillance aérienne : ils sont destinés à détecter des aéronefs évoluant à moyenne et basse altitude à des distances supérieures à 400 km. Capables d'une détection volumétrique, ils seront en mesure de créer des pistes 3D (position et altitude) de ces objets [20].

➤ Les radars de surveillance maritime, moins complexes que les précédents : ils sont destinés à la détection des navires de surface (cibles de grande taille) ou des

éléments émergés des sous-marins (cibles de petite taille). Ils ne peuvent utiliser l'effet Doppler du fait de la faible vitesse des cibles, et ne les repéreront donc que si leur surface équivalente est supérieure à l'écho de retour du fouillis de mer. Des techniques particulières dont la compression d'impulsion et les antennes synthétiques devront être utilisées pour y parvenir [20].

➤ les radars de surveillance terrestre, destinés à détecter les véhicules au sol, ils utilisent l'effet Doppler pour les mobiles en mouvement (colonnes de véhicules) et la comparaison de cartes successives pour déceler les concentrations de véhicules. Souvent installés sur des hélicoptères [20].

➤ Radars de conduite de tir :Appelés aussi d'interception, ils sont installés dans la pointe avant des avions de combat (intercepteurs) qui sont chargés d'acquérir la ou les cibles désignées par les systèmes de surveillance, de les poursuivre et de délivrer au système d'armes de l'avion toutes les informations nécessaires à la réalisation de l'interception. Ils sont comme les systèmes sol capables d'une veille volumétrique dans un secteur donné, de fonctions de pistage et de poursuite et d'aide aux armements sélectionnés : désignation d'objectif et/ou illumination des cibles [20].

#### ■ Radars de navigation

Ces radars sont destinés à apporter une aide à la navigation des aéronefs, aide plus ou moins complexe et complète selon le type de mission envisagée. Ils sont capables de tout ou partie des fonctions suivantes :

- météorologie pour l'évitement des nuages dangereux ;
- recalage de navigation par mesure continue ou discontinue de la vitesse sol, et la reconnaissance de points fixes au sol par mesures cartographiques ;
- suivi de terrain par détection du profil du terrain à une distance suffisante devant l'avion, permettant un vol à altitude sol constante épousant au mieux le relief ;
- détection et localisation des obstacles à développement vertical (pylônes, câbles, lignes haute tension...). Les performances de ces systèmes sont telles que l'on peut envisager des « altitudes de garde » de 100 mètres à quelques dizaines de mètres [20].

## ■ Radars de reconnaissance du sol

Chargés d'effectuer une cartographie fine du sol avec une finesse d'image pouvant atteindre quelques mètres, ils utilisent la technique des antennes latérales ou synthétiques, ou SLAR (*Side Looking Airborne Radar*). De ce fait, leur faisceau d'antenne est dirigé perpendiculairement à la route de l'avion et couvre latéralement une portion de sol, la zone totale observée (ou fauchée) étant en outre définie par le chemin parcouru par l'avion. Les images prises à distance de sécurité (50 à 100 km) sont stockées à bord de l'avion, ou transmises par une liaison hertzienne à grand débit (environ 50 Mbit/s). De tels systèmes sont aussi embarqués sur les satellites d'observation radar [20].

### 1.6 Classification des systèmes capteurs

Dans le cadre de la surveillance aérienne, tous les systèmes destinés à faire cette fonction, que ça soit militaire ou civile possèdent un module de pistage des cibles. Ce module comporte lui-même plusieurs sous-modules utilisant un ou plusieurs capteurs.

#### 1.6.1 Les systèmes à capteur unique

Le module de pistage de cibles est représenté à la figure 1.7. Supposons que nous ayons déjà plusieurs pistes formées. Lorsqu'une mesure est rapportée, elle est associée à une des pistes déjà existantes par l'ensemble fenêtrage-corrélation. Cet ensemble n'est en fait qu'une unité d'association des mesures. Le fenêtrage vérifie si les données positionnelles de la mesure se situent à l'intérieur d'une zone autour de la prédiction d'une des pistes [11].

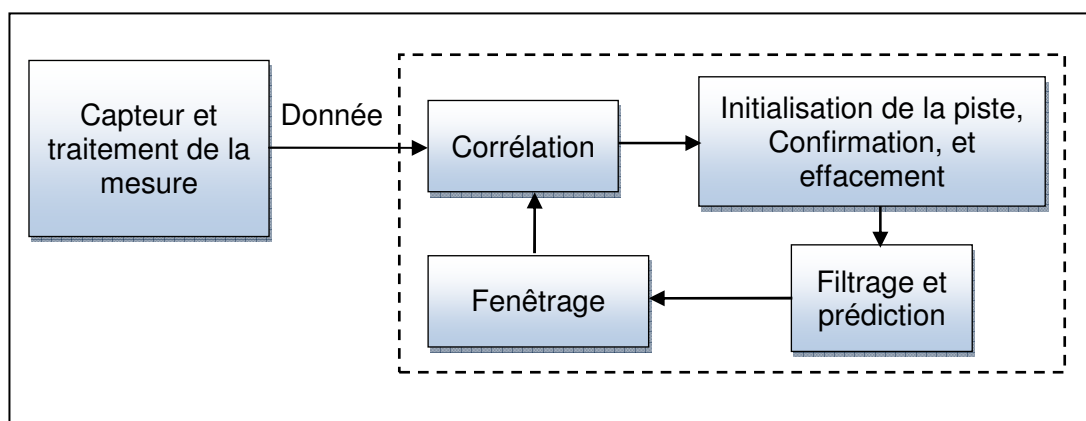


Figure 1.7 : Schéma d'un module de pistage de cibles à capteur unique

### 1.6.2 Les systèmes multi-capteurs

Lorsque le système est composé de plusieurs capteurs et que ceux-ci sont répartis dans l'espace, il faut ajouter une unité d'alignement. Cette unité d'alignement sert à transposer les mesures de chaque capteur dans un même système de coordonnées. Dans ce cas, le schéma est à peu près le même que pour le cas avec un seul capteur, à la différence qu'il y a plusieurs capteurs de même qu'une unité d'alignement, tel que montré à la figure 1.8 [42].

Habituellement, la diversité géométrique des capteurs améliore le pistage, car les chances sont plus élevées que la cible soit toujours dans la zone d'observation d'au moins un des capteurs.

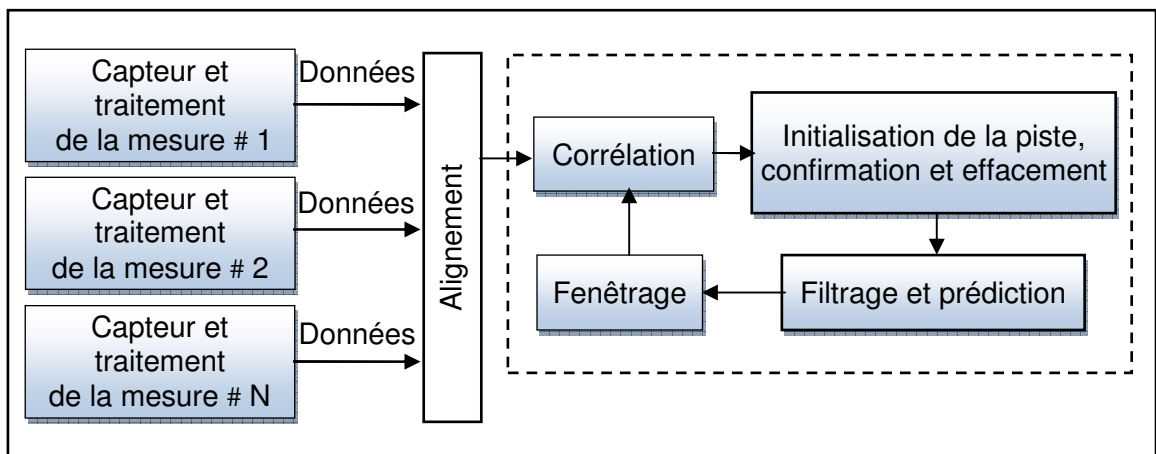


Figure 1.8 : Schéma d'un module de pistage de cibles à capteur unique

#### ■ Les systèmes multi-plateformes centralisés

Une architecture centralisée (figure 1.9) est celle dans laquelle chaque plate-forme envoie les mesures de ses capteurs à une unité centrale de traitement où la poursuite est effectuée.

L'architecture centralisée c'est une architecture de base contre les autres architectures qui peuvent être comparés. Cependant, L'architecture centralisée à un seul problème qui est la surcharge de communication due à la poursuite des états et les matrices de covariance doit être renvoyés à distance de plates-formes, et le système des retards [46].

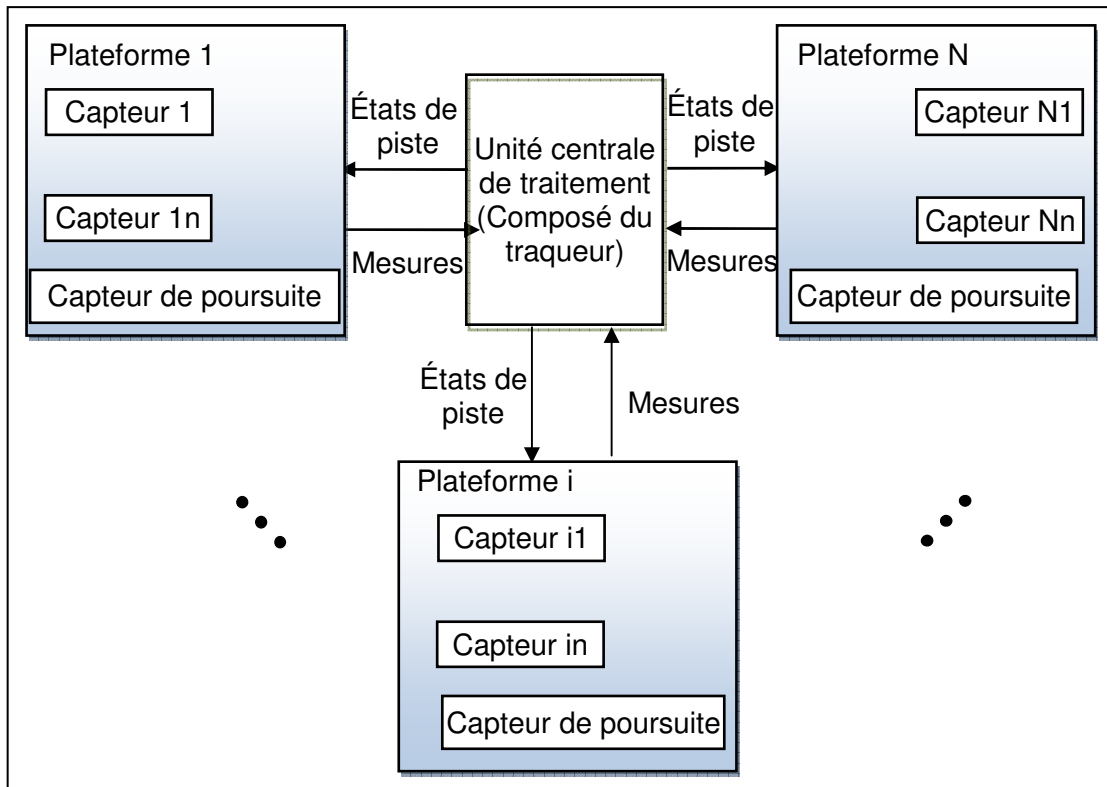


Figure 1.9 : Architecture multi-plateformes centralisée

#### ■ Les systèmes multi-capteurs centralisés

Dans les systèmes centralisés représentés dans la figure 1.10, on envoie les données numériques telles qu'elles sont acquises par le capteur, sans traitement préalable, vers un centre de fusion sur lequel aura lieu l'intégration. Cette approche permet de diminuer la complexité des capteurs périphériques, mais implique une surcharge en terme de capacité de calcul centrale et en terme de flux d'informations entre les différents composants du système [42].

Cette architecture permet de prendre une décision directe à partir de toutes les informations venant de toutes les sources, sans perte d'éléments de jugement à cause de sous-traitements locaux ; dans ce modèle de fusion globale aucune information n'est négligée au prix d'une complexité plus grande.

Au delà de l'architecture considérée, le processus de fusion de données comportera toujours quatre étapes bien définies : modélisation, estimation, combinaison et décision, pour lesquelles on devra choisir un formalisme mathématique concret [42].

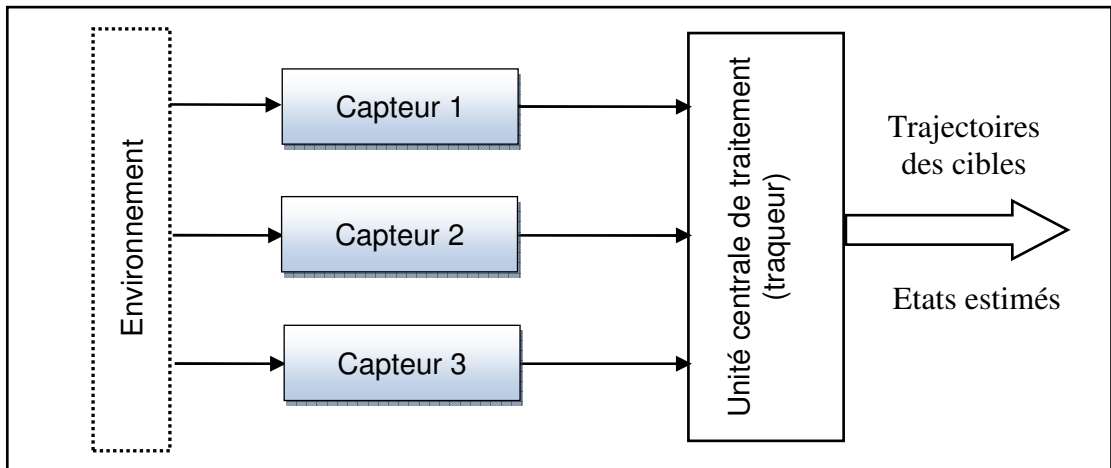


Figure 1.10 : Schéma d'un système multi-capteurs centralisés

### ■ Les systèmes multi-capteurs décentralisés

Dans les systèmes décentralisés représentés dans la figure 1.11, une partie du traitement est associée directement à chaque capteur et s'effectue à niveau local, de sorte que les données envoyées au système central possèdent un caractère symbolique au delà des simples mesures numériques [42].

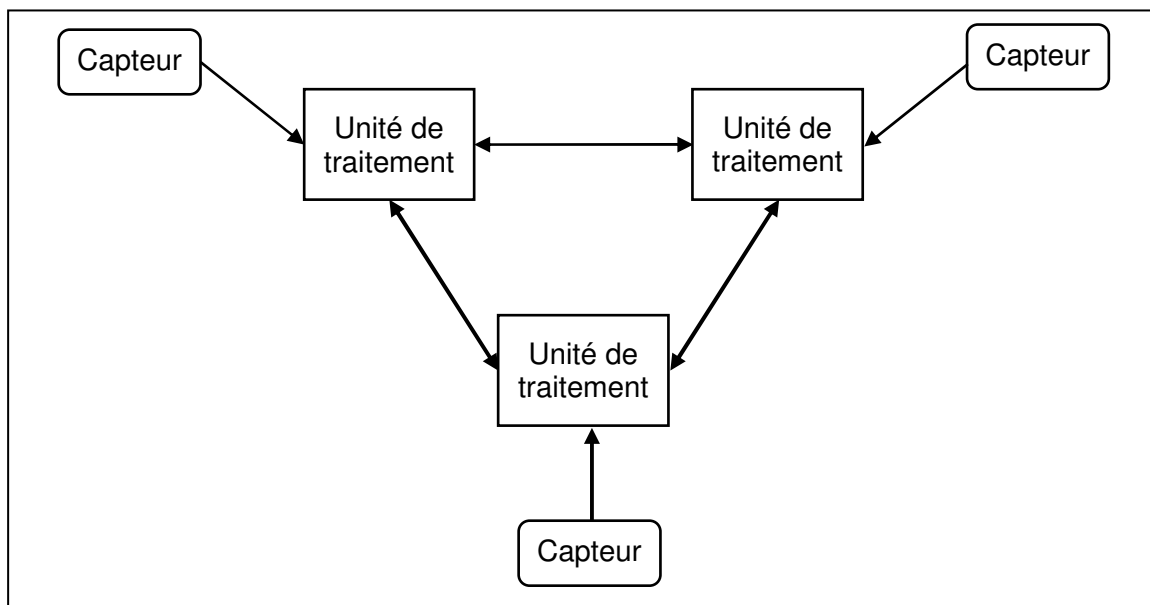


Figure 1.11 : Schéma d'un système multi-capteurs décentralisés

Du point de vue de la fusion de données, cette architecture correspond bien au modèle de la « fusion de décisions », selon lequel on prend d'abord des décisions locales au niveau de chaque source séparément pour les

fusionner après dans une décision globale. Cette architecture a un avantage et un inconvénient qui sont:

- Avantage : il est très approprié quand les sources ne sont pas disponibles simultanément, qu'il facilite le développement de procédures spécifiques pour chaque source (et donc l'obtention de réponses plus rapides ou mieux adaptées, ce qui peut être très intéressant pour des systèmes à temps réel) et qu'il facilite l'introduction de sources supplémentaires [42].
- Inconvénient : on peut citer la perte de certaines informations qui restent au niveau local, une plus grande difficulté pour la prise en compte des possibles corrélations ou dépendances entre cibles et capteurs, ou encore une plus grande difficulté pour la gestion des possibles conflits causés par des décisions locales contradictoires [42].

### 1.7 Le problème des mesures hors séquence (OOSM)

Nous considérons un système comportant deux capteurs qui mesurent l'état d'objets environnants et transmettent ces informations par l'intermédiaire d'un système de temps à une fusion / prédiction principale (voir la figure 1.12) [38].

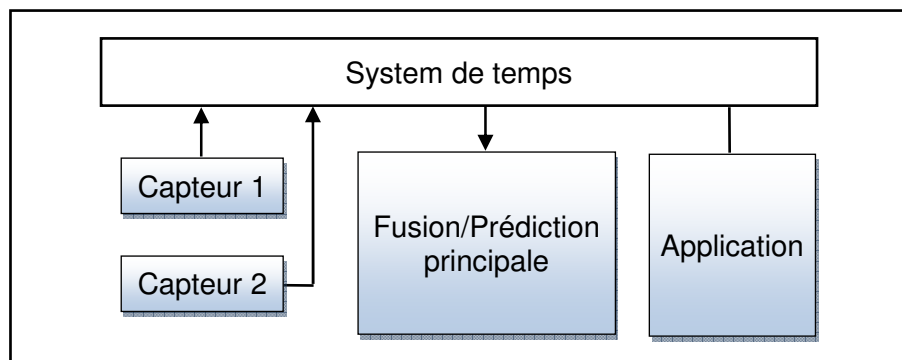


Figure 1.12 : Capteur de fusion système

Dans les systèmes de poursuite multi-capteurs, des informations sur le même objet peuvent arriver hors séquence, c'est-à-dire pas dans l'ordre chronologique. Souvent, le phénomène OOSM (Out Of Sequence Measurement) est causé par un système de transmission indéterminé, où le temps de transmission d'un message peut varier tant que un message d'une prochaine mesure peut dépasser une nouvelle mesure [38].

La figure 1.13 montre une situation d'un problème OOSM indépendant du système de communication. En raison des différents prétraitements, la mesure de capteur 1 est reçue après la mesure du capteur 2 au centre principal de fusion, alors qu'elle aurait dû être reçue avant : la mesure du capteur 1 est donc considérée comme une mesure OOSM [38].

Comme le filtre de Kalman ne prend pas en charge le problème des mesures hors séquence, des solutions algorithmique et architecturale ont été développées pour résoudre ce problème.




Figure 1.13 : L'origine des mesures hors séquence (OOSM)

Avant l'arrivée des mesures échantillonnées en mémoire, aucune mesure n'est délivrée par le système fusion/prédiction principal. Dans la mémoire, les mesures sont classées par ordre chronologique. Kaempchen et al examine en premier lieu la durée maximale entre l'enregistrement de la mesure et la fusion de cette dernière. Il se distingue entre les cas où il connait seulement la durée maximale de cycle de temps de mesure, et des cas où il connait tout le cycle des temps de mesure disponible [38].

Une autre façon de résoudre le problème OOSM est d'utiliser de nouveaux algorithmes appelés "algorithmes avancés". Ces algorithmes font le filtrage et la poursuite avec traitement de retard de mesure, et utilisent l'information (la mesure) du capteur plus rapide, et la décision délivrée par le système de fusion / prédiction [38].



## 1.8 Types de cibles

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

- Cibles non manœuvrantes (Figure 1-14 (a)) : la cible suit une trajectoire rectiligne à vitesse constante sans changement brusque de mouvement.
- Cibles manœuvrantes (Figure 1-14 (b)) : la cible peut à tout moment subir un changement de mouvement (accélération, décélération, virage).

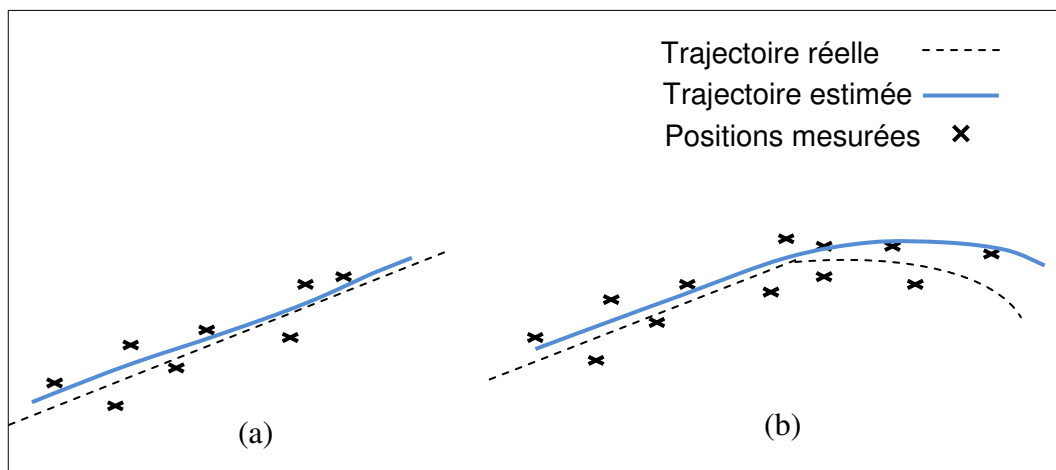


Figure 1.14 : Cibles (a) non manœuvrantes (b) manœuvrantes

### 1.8.1 Cibles non manœuvrantes

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

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

où  $\{x_t\}$  désigne le processus état du mobile (typiquement position, vitesse,...) de son centre de gravité) et  $\{v_t\}$  un bruit d'état,  $F$  est la matrice de transition,  $G$  permet de lier le bruit de modélisation  $v_t$  au vecteur d'état. Les mesures  $z_t$  (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  $\hat{x}_t = x_t - \hat{x}_t$  [37].

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

### 1.8.2 Cibles manœuvrantes

Dans le cas de cibles manœuvrantes, l'accélération du mobile comporte alors, en plus de fluctuations autour d'une moyenne nulle, une partie quasi discontinue et non linéaire correspondant aux manœuvres commandées par le pilote. L'apparition soudaine de ce terme commandé appelle une augmentation de la bande passante du pisteuse 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 :

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

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.

$\phi$  est un processus ponctuel ( $d\phi_t = 0$  sauf aux instants de manœuvres) et  $b_\phi x(t)$  relie les sauts de  $\phi$  aux manœuvres considérées [37].

Dans ces conditions, un filtre de Kalman classique est insuffisant, on doit faire alors appel à des dispositifs de détection de manœuvres incorporés dans le système de poursuite pour pouvoir suivre avec précision les trajectoires des cibles. La description de ces dispositifs fait l'objet des paragraphes suivants [37].

### 1.9 Détecteur de manœuvre

La poursuite des cibles manœuvrantes est un thème revenant fréquemment dans le domaine militaire.

En effet, la majorité des systèmes tactiques nécessitent la poursuite de cibles manœuvrantes 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 c'est montré dans la figure (1-15).

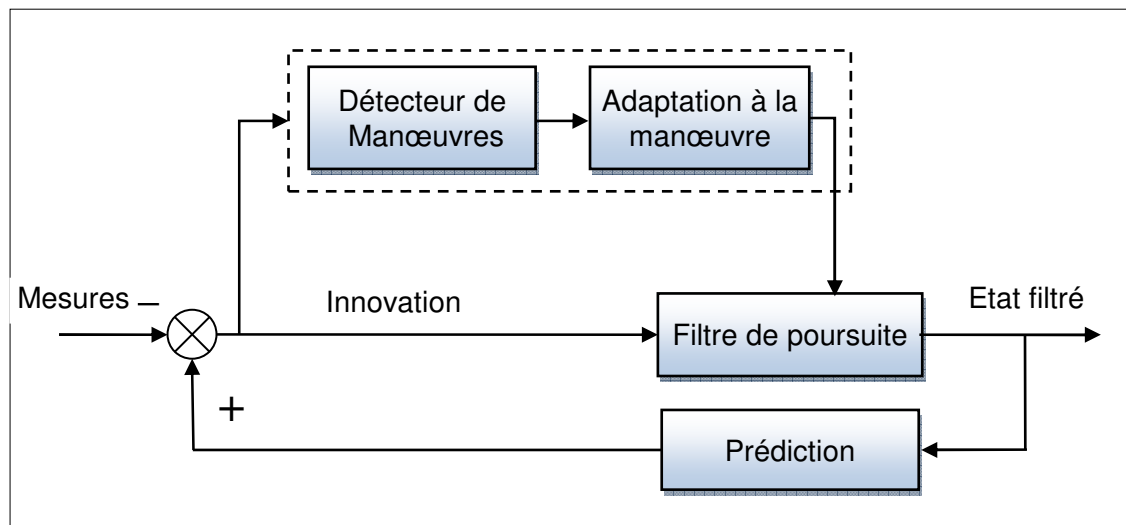


Figure 1.15 : Processus de filtrage en présence d'un détecteur de manœuvre

### 1.9.1 Techniques de détection de manœuvres

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

$$\tilde{z}(k+1) = z(k+1) - H\hat{x}(k+1|k) \quad 1.3$$

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

$$P(k) = HP(k|k-1)H^T + R \quad 1.4$$

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 [37].

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 manœuvre ou non. La sommation de l'innovation  $\tilde{z}(k)$  sur toute la longueur  $L$  de la fenêtre est définie par :

$$D_L(k) = \sum_{i=k-L+1}^k \tilde{z}(i) \begin{cases} \text{oui} \\ \nearrow \\ \searrow \\ \text{non} \end{cases} \eta \quad 1.5$$

La statistique  $D_L(k)$  est une variable aléatoire gaussienne.  $\tilde{z}(i)$  c'est l'innovation et  $\eta$  c'est une décision.

➤ 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 :

$$B_{m,k}(k) = \sum_{i=0}^{m-1} I(k-i) \begin{cases} \text{oui} \\ \nearrow \\ \searrow \\ \text{non} \end{cases} \eta \quad 1.6$$

Avec  $m$ , la longueur de la fenêtre utilisée et la statistique  $B_{m,k}(k)$  est une variable aléatoire de distribution binomiale.  $I(k-i)$  c'est l'innovation.

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

$$\rho(k) = \tilde{z}^t(k) P^{-1}(k) \tilde{z}(k) \begin{cases} \text{oui} \\ \nearrow \\ \searrow \\ \text{non} \end{cases} \eta \sum_{i=0}^{m-1} I(k-i) \quad 1.7$$

$\rho(k)$  est une variable aléatoire, de loi de probabilité Chi2 à  $n_z$  degrés de liberté ( $n_z$  représente la dimension du vecteur de mesure).

Cette technique peut être aussi utilisée pour évaluer le degré de la manœuvre qui est utile lors de l'utilisation d'un banc de filtres  $\alpha\beta$ .

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.

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.

### 1.9.2 Techniques basées sur l'estimation de l'accélération

Lors de l'utilisation d'un filtre de poursuite linéaire, la séquence de l'innovation contient en plus de la composante habituelle du bruit due 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  $\gamma$ . Si on considère le retard de détection, l'évaluation de  $\gamma$  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  $(t_0, \gamma)$  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  $(t_0, \gamma)$  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 nouvelle méthode d'estimation basée sur la minimisation de la covariance de l'estimation a vu le jour.

C'est une méthode récursive 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 manœuvrantes, et présente l'avantage de la facilité d'implémentation vu son caractère récursif.

Ces méthodes de détection de manœuvre basées sur l'estimation de l'accélération sont très intéressantes lors de l'utilisation des filtres  $\alpha\beta$ , elles permettent en plus de la détection, une adaptation du filtre pour diminuer les erreurs du système causé par la manœuvre. Par ailleurs, lors du choix d'une méthode, on doit tenir compte surtout de son temps de calcul et de sa complexité d'implémentation.

### 1.10 Adaptation à la manœuvre

Une fois qu'une manœuvre est signalée par le détecteur, 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).

#### 1.10.1 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 manœuvrabilité figure 1.16. 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.

Si l'on considère que l'accélération est un bruit blanc, en l'absence de manœuvre, le bruit est supposé au niveau  $Q_1$ . Une fois que la manœuvre 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 manœuvre.

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 manœuvre, la moyenne de l'innovation diminue et tend vers zéro mais sa variance est augmentée.




Figure 1.16 : Adaptation des dimensions de la fenêtre de corrélation

### 1.10.2 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 manœuvre 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 (1-17).

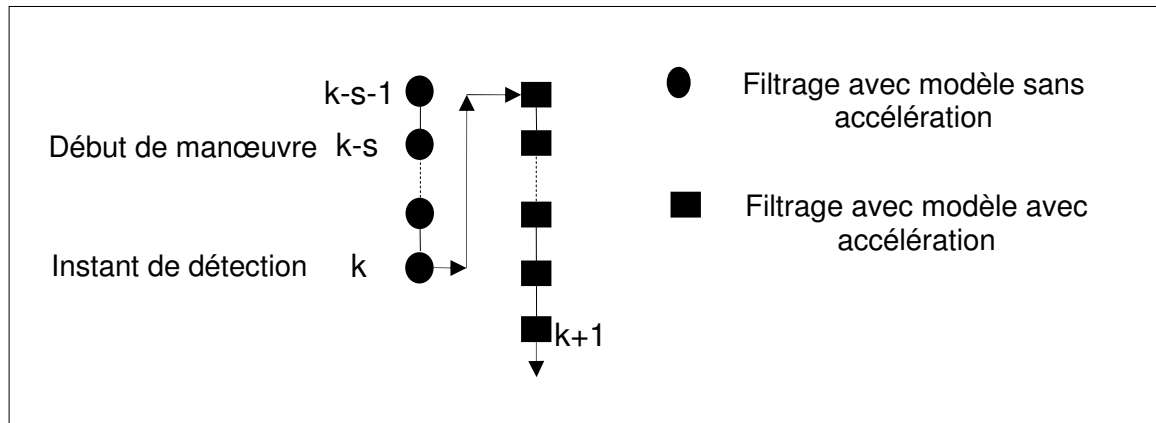


Figure 1.17 : Filtrage avec changement de la dimension du filtre

L'approche basée sur le changement de l'ordre du modèle d'état, permet une bonne poursuite des cibles en phase de manœuvres, 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 manœuvre.

### 1.10.3 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  $\{\tilde{z}(1), \tilde{z}(2), \dots, \tilde{z}(k)\}$ .

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.

### 1.10.4 Approche à Modèles Multiples

L'approche à Modèles Multiples (MM), quand nous développerons dans le troisième 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 (1-18).

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.

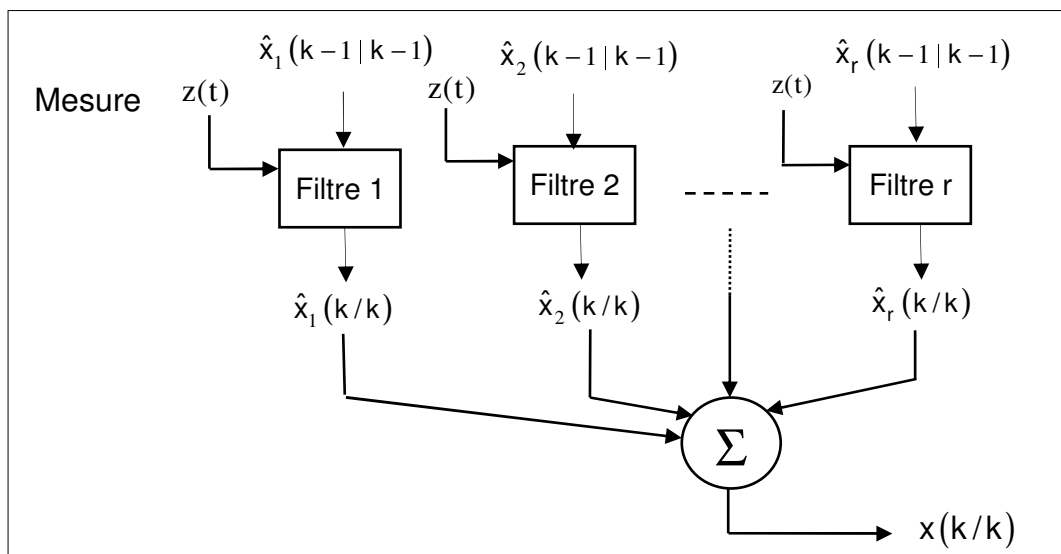


Figure 1.18 : Schéma bloc d'un système MM

### ■ 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 (1-19).

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

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

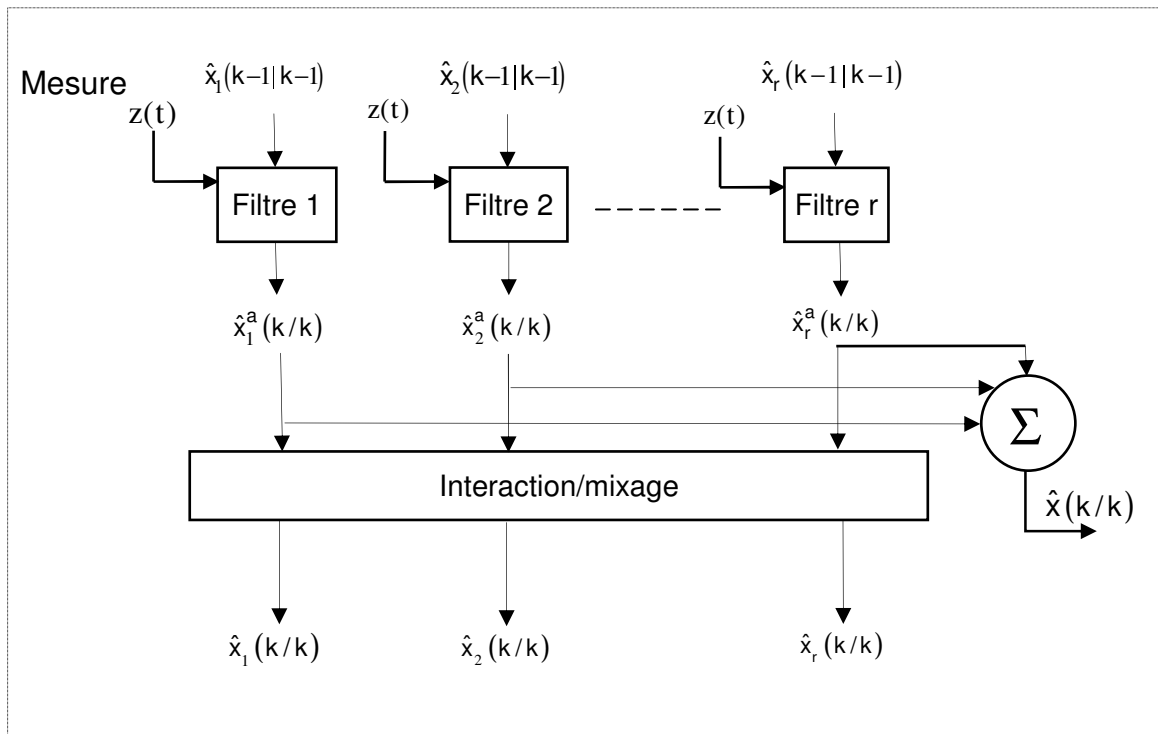


Figure 1.19 : Schéma bloc du système à Modèles Multiples Interactifs (IMM)

### 1.11 Conclusion

Dans ce chapitre, nous avons d'abord commencé par donner une définition de la poursuite et les capteurs utilisés dans cette dernière. Puis nous avons présenté brièvement les systèmes multi-capteurs utilisés dans notre travail. Ensuite, nous avons illustré les types de cibles. Le dernier point était consacré à la description du détecteur de manœuvre où nous avons donné un ensemble d'approches d'adaptation des paramètres du filtre de poursuite.

## CHAPITRE 2

# LE FILRAGE DE KALMAN

### 2.1 Introduction

Le filtrage consiste à estimer de façon récursive un état d'observations. Le domaine d'application principal est la localisation, la navigation et la poursuite de mobiles, dans le domaine militaire, mais aussi en robotique mobile, en vision par ordinateur, en communications sans-fil, où il s'agit de combiner : un modèle à priori de déplacement du mobile, des mesures issues de capteurs.

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, et le filtre  $\alpha\beta$ , qui sont les plus utilisées dans la poursuite radar. Afin d'obtenir des erreurs de filtrage acceptables lors des accélérations importantes, un détecteur de manœuvre est souvent intégré dans l'algorithme de poursuite. Il sert à détecter le début et la fin de manœuvres, pour adapter les paramètres du filtre, afin d'assurer une poursuite permanente.

Les performances du filtre dépendent étroitement du système de coordonnées de référence utilisées, et du modèle adopté du mouvement de la cible. Pour des mouvements circulaires, il est préférable d'utiliser le système de coordonnées des pistes orientées, qui est le mieux adapté à la poursuite des cibles en virages. Le système de coordonnées cartésiennes est souvent utilisé pour la poursuite des cibles en mouvements rectilignes.

### 2.2 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)...

### 2.3 Le filtre de Kalman discret

En 1960, R.E. Kalman a publié son célèbre article décrivant une solution récursive au problème de filtrage linéaire de donnée discrète.

Depuis cette époque, grâce au développement dans de grandes parties dans le calcul numérique, le filtre de Kalman a été le sujet de la recherche et de l'application étendue, en particulier dans le secteur de la navigation autonome ou assistée.

#### 2.3.1 Le processus d'estimation

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

$$x_k = Fx_{k-1} + Gu_{k-1} + w_{k-1} \quad 2.1$$

Avec la mesure  $z \in \mathfrak{R}^{nm}$  qui est :

$$z_k = H x_k + v_k \quad 2.2$$

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, blanc, et avec des probabilités de distributions normales :

$$p(w) \approx N(0, Q) \quad 2.3$$

$$p(v) \approx N(0, R) \quad 2.4$$

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 dimensions  $n \times n$  dans l'équation (2.1) 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  $u \in \mathfrak{R}^1$  à l'état  $x$ . La matrice  $H(k)$  de dimension  $m \times n$  dans l'équation de mesure (2.2) relie l'état à la mesure  $z(k)$ . Dans la pratique  $H$  pourrait changer chaque fois avec l'état ou la mesure [29].

### 2.3.2 Les origines de calcul du filtre

$\hat{x}^-(k) \in \mathfrak{R}^n$  est l'estimation d'état à priori à l'étape  $k$  connaissant le processus avant l'étape  $k$ , et  $\hat{x}(k) \in \mathfrak{R}^n$  pour être notre estimation d'état, à posteriori à l'étape  $k$  donnant la mesure  $z(k)$ . Nous pouvons alors définir à priori et à posteriori les erreurs d'estimations comme :

$$e_k^- = x_k - \hat{x}_k^- \quad \text{et} \quad e_k = x_k - \hat{x}_k$$

La covariance à priori d'erreur d'estimation est alors :

$$\bar{P}(k) = E \left[ e^-(k) e^-(k)^T \right] \quad 2.5$$

Et la covariance à posteriori d'erreur d'estimation est :

$$P(k) = E \left[ e(k) e(k)^T \right] \quad 2.6$$

En dérivant les équations pour le filtre de Kalman, nous commençons de trouver une équation qui calcul à posteriori une estimation d'état  $\hat{x}_k$  comme combinaison linéaire d'une estimation à priori  $\hat{x}_k^-$  et une différence pondérée entre une mesure réelle  $z(k)$  et la prédiction de la mesure  $H\hat{x}_k^-$  comme montré ci-dessous dans l'équation (2.7).

$$\hat{x}(k) = \hat{x}^-(k) + K \left( z(k) - H\hat{x}^-(k) \right) \quad 2.7$$

La différence  $z_k - H\hat{x}_k^-$  dans (2.7) s'appelle l'innovation de mesure, ou le résidu.

Le résidu reflète la différence entre la mesure prévue  $H\hat{x}_k^-$  et la mesure réelle  $z_k$ .

Un résidu nul signifie que les deux sont en accord total.

La matrice  $K$  de dimensions  $n \times m$  dans (2.7) est calculée de sorte à être le gain ou le facteur de mixage qui minimise la covariance d'erreur à posteriori (2.6).

Cette minimisation peut être accomplie en remplaçant d'abord (2.7) dans la définition de  $e_k$  ci-dessus, substituant celle-ci dans (2.6), développant les espérances indiquées, calculant et annulant la dérivée de la trace du résultat en fonction de  $K$  et puis le résolvant pour  $K$ . La forme résultante de  $K$  qui minimise (2.6) est donnée par :

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1} = \frac{P_k^- H^T}{H P_k^- H^T + R} \quad 2.8$$

Les équations de filtre de Kalman peuvent être présentées sous différentes formes. L'équation (2.8) représente le gain de Kalman sous une forme connue.

En observant (2.8), nous voyons que lorsque la covariance d'erreur de mesure tend vers zéro, le gain  $K$  amplifie le résidu. Spécifiquement :

$$\lim_{R_k^- \rightarrow 0} K_k = H^{-1}$$

D' autre part, lorsque la covariance d'erreur d'estimation à priori tend vers zéro, le gain  $K$  amplifie moins le résidu. Spécifiquement :

$$\lim_{P_k^- \rightarrow 0} K_k = 0$$

Une autre manière de voir l'effet de la pondération  $K$  est que, comme la covariance d'erreur de mesure  $R$  tend vers zéro, la mesure réelle  $z_k$  est favorisée de plus en plus, alors que la mesure prévue  $H\hat{x}_k^-$  est favorisé de moins en moins.

D' autre part, comme la covariance d'erreur d'estimation à priori  $P_k^-$  tend vers zéro la mesure réelle  $z_k$  est favorisée de moins en moins, alors que la mesure prévue  $H\hat{x}_k^-$  est favorisée de plus en plus.

Tout ce qu'on vient de citer se résume dans le paragraphe suivant :

➤ Lorsqu'il y a une grande incertitude sur le vecteur d'état (le modèle)  $\Rightarrow P$  grande  $\Rightarrow$  gain  $K$  grand  $\Rightarrow$  innovation favorisée

➤ Lorsqu'il y a une grande incertitude sur la mesure  $\Rightarrow w$  grand  $\Rightarrow$  gain  $K$  petit  $\Rightarrow$  prédiction favorisée.

On résume les propriétés de ce filtre dans la figure 2.1 :




Figure 2.1 : Interprétation du filtre de Kalman

### 2.3.3 Les origines probabilistes du filtre

La justification de (2.7) dérive de la probabilité d'estimation à priori  $\hat{x}_k^-$  conditionné sur toutes les mesures antérieures  $z_k$  (règle de Bayes).

Pour le moment, il est suffisant de dire que le filtre de Kalman maintient les deux premiers moments de la distribution d'état :

$$E[x_k] = \hat{x}_k$$

$$E[(x_k - \hat{x}_k)(x_k - \hat{x}_k)^T] = P_k$$

L'estimée d'état à postériori (2.7) reflète la moyenne (le premier moment) de la distribution d'état qui est normalement distribuée si les conditions (2.3) et (2.4) sont réunies. L'estimé à posteriori de la covariance d'erreur (2.6) reflète la variance de la distribution d'état (le deuxième moment). En d'autres termes :

$$p(x_k | z_k) \propto N(E[x], E[(x_k - \hat{x}_k)(x_k - \hat{x}_k)^T]) \\ = N(\hat{x}_k, P_k)$$

### 2.3.4 L'algorithme du filtre de Kalman discret

Nous commençons cette section par un aperçu général sur le filtre de Kalman discret. Après présentation de cet aperçu, nous résumerons les équations spécifiques et leur utilisation dans ce type de filtre.

Le filtre de Kalman estime un processus en employant une forme de contre-réaction. Le filtre estime l'état du processus à un moment donné et puis obtient la réaction sous forme de mesures bruitées. Les équations du filtre de Kalman se divisent en deux groupes : les équations de mise à jour de temps et les équations de mise à jour de la mesure. Les équations de mise à jour de temps sont projetées en avant (dans le temps) les estimations d'état actuel et des covariances d'erreur pour obtenir les estimations à priori pour la prochaine étape. Les équations de mise à jour de mesure constituent la contre-réaction c'est-à-dire qu'elles incorporent une nouvelle mesure dans l'estimation à priori pour obtenir une estimation à posteriori améliorée.

Les équations de mise à jour de temps peuvent également être considérées comme des équations de prédiction, alors que les équations de mise à jour de mesure peuvent être considérées comme des équations de correction.

En effet, l'algorithme final d'estimation ressemble à un algorithme de prédiction/correction pour la résolution de problèmes numériques comme représenté dans la figure (2-2).

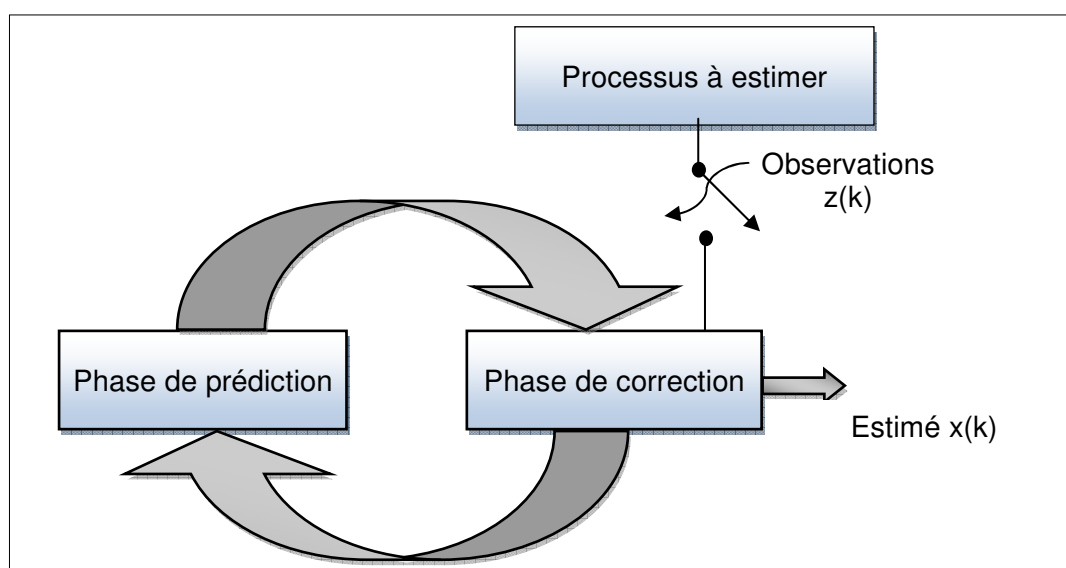


Figure 2.2 : Le cycle du filtre de Kalman discret



Les équations spécifiques pour les mises à jour de temps et de mesure sont présentées ci-dessous :

$$\hat{x}_k = F\hat{x}_{k-1} + Gu_{k-1} \quad 2.9$$

$$P_k^- = FP_{k-1}^- F^T + Q \quad 2.10$$

Notons encore comment les équations de mise à jour de temps dans les équations ci-dessous projettent les estimations d'état et de covariance en avant de l'instant  $k-1$  à l'instant  $k$ . Les matrices  $F$  et  $G$  sont tirées de (2.1),  $Q$  de (2.3).

$$K_k = P_k^- H^T (HP_k^- H^T + R)^{-1} \quad 2.11$$

$$\hat{x}(k) = \hat{x}_k^- + K_k (z_k - H\hat{x}_k^-) \quad 2.12$$

$$P_k = (I - K_k H) P_k^- \quad 2.13$$

La première tâche pendant la mise à jour de mesure est de calculer le gain de Kalman  $K_k$ . Notons que l'équation donnée dans (2.11) est identique à celle de (2.8). La prochaine étape est de calculer une estimation d'état à postériori en incorporant la mesure dans (2.12). L'étape finale est d'obtenir une estimation de la covariance d'erreur à posteriori par l'intermédiaire de (2.13).

Ensuite, à chaque instant, le processus se répète avec les estimations précédentes à postériori pour prédire les nouvelles estimations à priori. Cette caractéristique de récursivité est un des grands avantages du filtre de Kalman par rapport à d'autres types de filtre. La figure (2-2) offre une image complète du fonctionnement du filtre, combinant le diagramme à haut niveau de la figure (2-3) avec les équations du filtre.

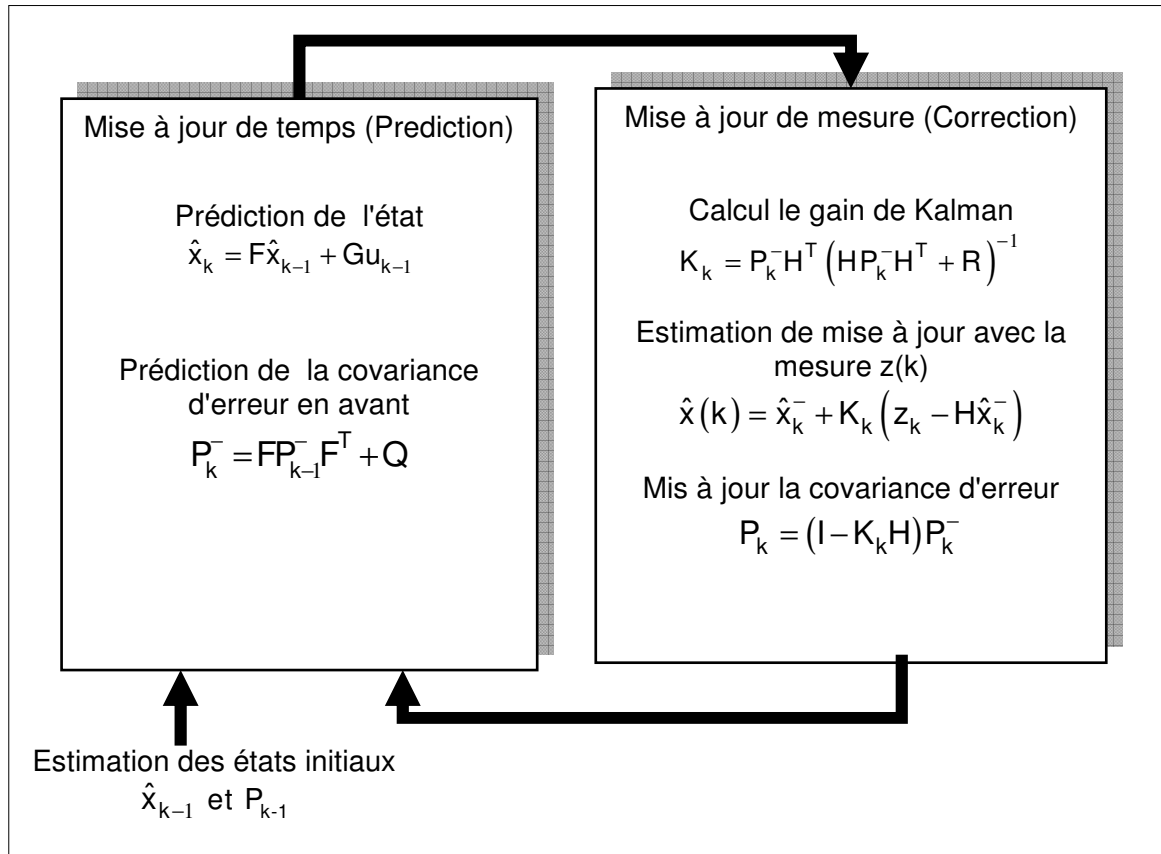


Figure 2.3 : Schéma de l'algorithme du filtre de Kalman

### 2.3.5 Les paramètres et le réglage du filtre

Dans l'utilisation du filtre, La covariance de bruit de mesure  $R$  est habituellement mesurée avant l'utilisation du filtre. La mesure de cette dernière est généralement possible, parce que nous devons être capables de mesurer le processus n'importe comment (pendant le fonctionnement du filtre), ainsi nous devrions généralement pouvoir prendre hors-ligne un nombre d'échantillons de mesure afin de déterminer la variance du bruit de mesure.

La détermination de la covariance de processus de bruit  $Q$  est généralement plus difficile car, typiquement, nous n'avons pas la capacité d'observer directement le processus que nous estimons.

Parfois un modèle de processus relativement simple peut produire des résultats acceptables si on injecte assez d'incertitude dans le processus par l'intermédiaire du choix de  $Q$ .

Dans d'autres cas, des performances élevées peuvent être obtenues en réglant les paramètres de filtre R et Q.

Le réglage est habituellement réalisé hors-ligne, fréquemment avec l'aide d'un autre filtre de Kalman inséré dans le processus et généralement désigné sous le nom d'identification de système.

Enfin, notons que dans les conditions où Q et R sont des constantes, la matrice de covariance  $P_k$  de l'erreur d'estimation et le gain de Kalman  $K_k$  se stabilisent rapidement et tendent vers des constantes. Si c'est le cas, ces paramètres peuvent être calculés à l'avance en faisant fonctionner le filtre hors-ligne, ou par exemple en déterminant la valeur d'équilibre de  $P_k$ .

Cependant dans beaucoup de cas, les valeurs de Q et de R ne sont pas des constantes. Dans ces conditions, ils doivent être ajustés en fonction des besoins.

#### 2.4 Le filtre de Kalman étendu (EKF) :

Comme c'est décrit précédemment, le filtre de Kalman s'intéresse au problème général de l'estimation de l'état  $x \in \mathfrak{R}^n$  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 de 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).

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 :

$$x_k = f(x_{k-1}, u_{k-1}, w_{k-1}) \quad 2.14$$

Avec une mesure  $z \in \mathfrak{R}^m$  de la forme :

$$z_k = h(x_k, v_k) \quad 2.15$$

où les variables aléatoires  $w_k$  et  $v_k$  représentent les bruits d'état et de mesure comme en 2.3 et 2.4.

La fonction  $f$  non linéaire dans l'équation différentielle 2.14 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 de processus  $w_k$  de moyenne nulle. La fonction non linéaire  $h$  dans l'équation de mesure 2.15 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 :

$$\hat{x}_k = f(\hat{x}_{k-1}, u_{k-1}, 0) \quad 2.16$$

$$\hat{z}_k = h(\hat{x}_k, 0) \quad 2.17$$

où  $\hat{x}_k$  est une certaine estimation à postériori 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'optimalité de la règle de Bayes par la linéarisation.

Pour estimer le processus non linéaire, nous commençons d'écrire des nouvelles équations qui linéarisent les estimées autour de 2-16 et 2-17 :

$$x_k = \tilde{x}_k + A(x_{k-1} - \hat{x}_{k-1}) + Ww_{k-1} \quad 2.18$$

$$z_k = \tilde{z}_k + H(x_k - \tilde{x}_k) + Vv_k \quad 2.19$$

où :

- $x_k$  et  $z_k$  sont les vecteurs réels d'état et de mesure,
- $\tilde{x}_k$  et  $\tilde{z}_k$  sont les vecteurs approchés d'état et de mesure (2.16) et (2.17),

- $\tilde{x}_k$  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 :

$$A_{[i,j]} = \frac{\partial f_{[i]}}{\partial x_{[j]}}(\hat{x}_{k-1}, u_{k-1}, 0)$$

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

$$W_{[i,j]} = \frac{\partial f_{[i]}}{\partial w_{[j]}}(\hat{x}_{k-1}, u_{k-1}, 0)$$

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

$$H_{[i,j]} = \frac{\partial h_{[i]}}{\partial x_{[j]}}(\tilde{x}_k, 0)$$

- $V$  est la matrice Jacobienne des dérivées partielles de  $h$  en fonction

$$V_{[i,j]} = \frac{\partial h_{[i]}}{\partial v_{[j]}}(\tilde{x}_k, 0)$$

Maintenant, nous définissons une nouvelle notation pour l'erreur de prédiction :

$$\tilde{e}_{x_k} \equiv x_k - \hat{x}_k \tag{2.20}$$

et le résidu de mesure :

$$\tilde{e}_{z_k} \equiv z_k - \hat{z}_k \theta \tag{2.21}$$

Il faut se rappeler que dans la pratique, on n'a pas accès à  $x_k$  dans (2.20), c'est le vecteur réel d'état, c'est-à-dire la quantité qu'on essaye d'estimer. D'autre part, on a accès à  $z_k$  dans (2.21), qui est la mesure réelle qu'on utilise pour estimer  $x_k$ . En utilisant (2.20) et (2.21), nous pouvons écrire les équations d'erreur comme :

$$\tilde{e}_{x_k} \approx A(x_{k-1} - \hat{x}_{k-1}) + \varepsilon_k$$

2.22

$$\tilde{e}_{z_k} \approx H \bar{e}_{x_k} - \eta_k \tag{2.23}$$

où  $\varepsilon_k$  et  $\eta_k$  représentons de nouvelles variables aléatoires indépendantes ayant des moyennes nulles et des matrices de covariance  $WQW^T$  et  $VRV^T$ , avec  $Q$  et  $R$  données par (2.3) et (2.4) respectivement.

Notons que les équations (2.22) et (2.23) sont linéaires, et qu'elles ressemblent aux équations de différence et de mesure (2.1) et (2.2) du filtre de Kalman discret. Ceci nous motive pour utiliser le résidu de mesure  $\tilde{e}_{z_k}$  dans (2.1) et un deuxième filtre (hypothétique) de Kalman pour estimer l'erreur de prédiction  $\tilde{e}_{x_k}$  donnée par (2.22).

Cette estimation, notée  $\hat{e}_k$ , peut alors être utilisée avec (2.20) pour obtenir une estimation à posteriori d'état pour le processus non linéaire original comme :

$$\hat{x}_k = \tilde{x}_k + \hat{e}_{x_k} \quad 2.24$$

Les variables aléatoires de (2.22) et (2.23) ont approximativement les distributions de probabilité suivantes:

$$p(\tilde{e}_{x_k}) \sim N(0, E[\tilde{e}_{x_k} \tilde{e}_{x_k}^T])$$

$$p(\varepsilon_k) \sim N(0, W Q_k W^T)$$

$$p(\eta_k) \sim N(0, V R_k V^T)$$

Etant donné ces approximations et en annulant  $\hat{e}_k$ , l'équation du filtre de Kalman utilisée pour estimer  $\hat{e}_k$  est :

$$\tilde{e}_k = K_k \tilde{e}_{z_k} \quad 2.25$$

En substituant (2.25) de nouveau dans (2.24) et en se servant (2.21) nous voyons que nous n'avons pas besoin réellement du deuxième filtre (hypothétique) de Kalman :

$$\begin{aligned} \hat{x}_k &= \tilde{x}_k + K_k \tilde{e}_{z_k} \\ &= \tilde{x}_k + K_k (z_k - \tilde{z}_k) \end{aligned} \quad 2.26$$

L'équation (2.26) peut maintenant être employée pour la mise à jour de mesure dans le filtre de Kalman étendu, avec  $\tilde{x}_k$  et  $\tilde{z}_k$  tirés de (2.16) et (2.17) et le gain

de Kalman  $K_k$  venant de (2.11), avec la substitution appropriée pour la covariance d'erreur de mesure.

L'ensemble complet d'équations d'EKF est donné ci-dessous dans les équations (2.27) à (2.31).

$$\hat{x}_k^- = f(\hat{x}_{k-1}, u_{k-1}, 0) \quad 2.27$$

$$P_k^- = A_k P_{k-1} A_k^T + W_k Q_{k-1} W_k^T \quad 2.28$$

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + V_k R_k V_k^T)^{-1} \quad 2.29$$

$$\hat{x}_k = \hat{x}_k^- + K_k (z_k - h(\hat{x}_k^-, 0)) \quad 2.30$$

$$P_k = (I - K_k H_k) P_k^- \quad 2.31$$

La figure (2-4) montre une image complète du filtre EKF.

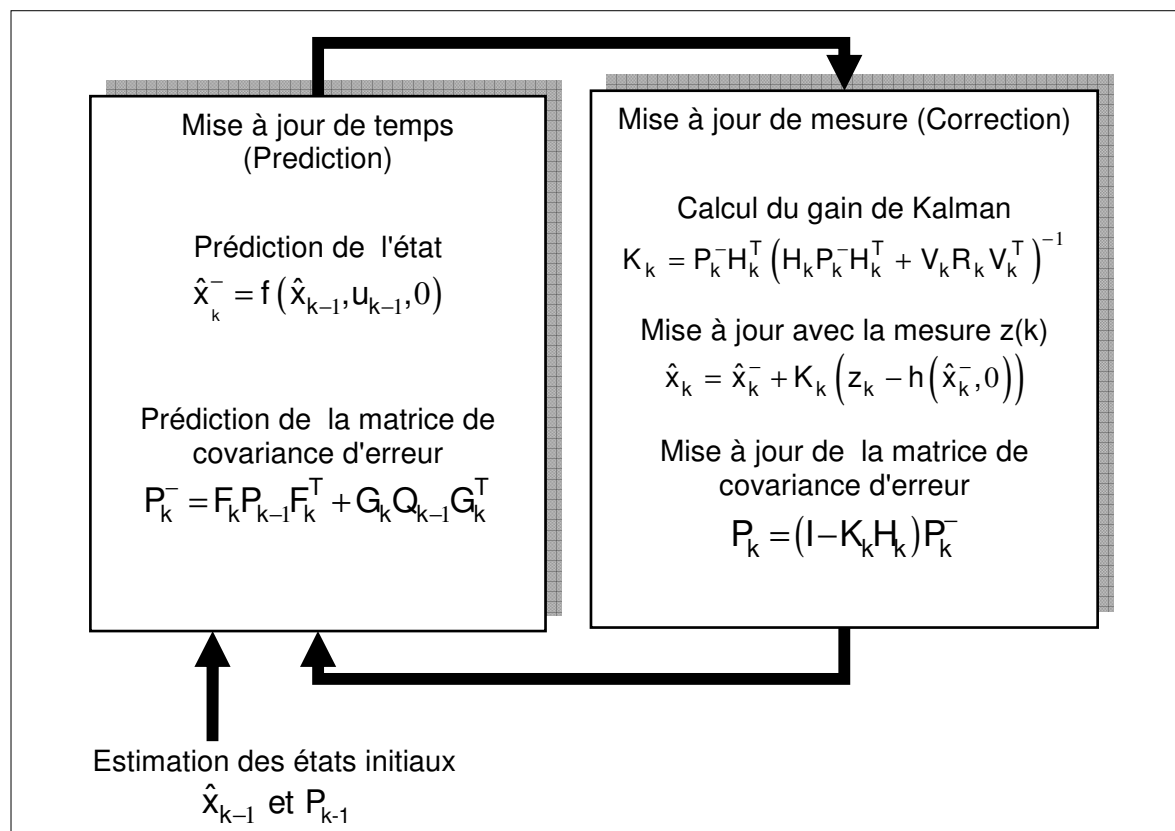


Figure 2.4 : Schéma de l'algorithme du filtre de Kalman étendu

## 2.5 Initialisation du filtre

Nous avons vu que le filtre de Kalman n'est en fait qu'un algorithme récursif. Il faut lui fournir donc un estimé à priori initial ainsi que la matrice de covariance de son erreur. Dans cette section, nous verrons comment choisir adéquatement ces paramètres initiaux afin d'assurer le bon fonctionnement du pistage.

De façon optimale, la matrice de covariance  $P(k)$  de l'erreur d'estimation doit représenter en tout le temps et le plus fidèlement possible la précision de la piste calculée.

Ce principe vaut aussi pour l'instant d'initialisation du filtre. Il arrive quelquefois de rencontrer une technique d'initialisation qui consiste à choisir n'importe quelle valeur pour  $x(0|-1)$  et à prendre  $P(0|-1)$  très grande. Cette méthode a comme désavantage de conserver  $P(k)$  élevée pendant une grande période, délaissant ainsi l'information apportée par les mesures durant cette période.

Une méthode plus efficace permet de conserver l'optimalité de la piste calculée. Dans le cas d'une mesure de position (abscisse et ordonné), supposons qu'à l'instant  $t = t(0)$  nous ayons en mémoire les deux vecteurs de mesures  $z(-1)$  et  $z(0)$  où  $z(k) = [x_m(k) \ y_m(k)]^T$  et que  $\Delta t(-1)$  représente l'intervalle de temps entre  $t(-1)$  et  $t(0)$ . Nous pouvons alors former l'estimé à priori initial du vecteur d'état (position et vitesse) de la manière suivante:

$$\hat{x}(0|-1) = \begin{bmatrix} z(0,1) \\ \frac{z(0,1) - z(-1,1)}{\Delta t(-1)} \\ z(0,2) \\ \frac{z(0,2) - z(-1,2)}{\Delta t(-1)} \end{bmatrix} \quad 2.32$$

où  $z(k, i)$  représente la  $i^{\text{ème}}$  composante du vecteur de mesure à l'instant  $t(k)$ . La matrice de covariance de l'erreur de l'estimé a priori initial est donnée par :



$$P(0|-1) = \begin{bmatrix} \sigma_x^2 & \frac{\sigma_x^2}{\Delta t(-1)} & \sigma_{xy}^2 & \frac{\sigma_{xy}^2}{\Delta t(-1)} \\ \frac{\sigma_x^2}{\Delta t(-1)} & \frac{2\sigma_x^2}{\Delta t(-1)^2} & \frac{\sigma_{xy}^2}{\Delta t(-1)} & \frac{2\sigma_{xy}^2}{\Delta t(-1)^2} \\ \sigma_{xy}^2 & \frac{\sigma_{xy}^2}{\Delta t(-1)} & \sigma_y^2 & \frac{\sigma_x^2}{\Delta t(-1)} \\ \frac{\sigma_{xy}^2}{\Delta t(-1)} & \frac{2\sigma_{xy}^2}{\Delta t(-1)^2} & \frac{\sigma_y^2}{\Delta t(-1)} & \frac{2\sigma_y^2}{\Delta t(-1)^2} \end{bmatrix} \quad 2.33$$

Les équations (2.32) et (2.33) permettent donc d'initialiser correctement le filtre de Kalman à partir des mesures [45].

## 2.6 Modèles d'état

Différents types de modèles ont été développés pour représenter tous les types de trajectoires rencontrées en pratique. Nous décrivons ici, trois types de modèles [45].

### 2.6.1 Modèle à vitesse constante (CV)

Un des plus simples modèles de poursuite utilise les coordonnées cartésiennes pour décrire la position et la vitesse de la cible [45].

Avec une dimension, nous utilisons la position  $x$  et la vitesse  $\dot{x}$  comme vecteur d'état  $X$ , soit :

$$X(t) = (x(t), \dot{x}(t))^T$$

Nous pouvons utiliser le modèle continu suivant :

$$\dot{X}(t) = \begin{pmatrix} \dot{x} \\ \ddot{x} \end{pmatrix} = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix} X(t) + \begin{pmatrix} 0 \\ 1 \end{pmatrix} v(t) \quad 2.34$$

où nous avons supposé une perturbation autour de la vitesse constante du modèle.

Si nous supposons que le bruit (accélération) est constant durant la période d'échantillonnage  $T$ , nous pouvons écrire le modèle discret sous la forme :

$$X_{t+1} = \begin{pmatrix} 0 & T \\ 0 & 0 \end{pmatrix} X_t + \begin{pmatrix} T^2/2 \\ T \end{pmatrix} v_t \quad 2.35$$

### 2.6.2 Modèle à accélération constante (CA)

En 1970, un filtre basé sur les techniques de Kalman est développé pour les cibles manœuvrantes. L'idée principale est de représenter les différentes formes de manœuvres des véhicules. La manœuvre dans ce cas est l'accélération supposés corrélée dans le temps [45].

Ceci est due au fait qu'on suppose que la cible accélérant à l'instant  $t$ , continue d'accélérer à l'instant  $t+\tau$ , où  $\tau$  est un petit incrément de temps. Un tel modèle est représenté par la fonction d'auto-corrélation

$$E[\ddot{x}(t), \ddot{x}(t+\tau)] = \sigma^2 e^{-\alpha|\tau|} \quad 2.36$$

où  $\sigma^2$  est la variance de l'accélération.

L'équation dynamique de l'accélération peut s'écrire :

$$\frac{d}{dt} \ddot{x}(t) = -\alpha \ddot{x}(t) + v(t) \quad 2.37$$

où  $v(t)$  est un bruit blanc de variance  $2\alpha\sigma^2\delta(\tau)$ . Le modèle est connu sous la désignation de processus de Gauss-Markov du premier ordre.

En supposant un vecteur d'état de composantes suivante : la position, la vitesse et l'accélération, s'écrit :

$$\dot{X}(t) = \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & -\alpha \end{pmatrix} X(t) + \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} v(t) \quad 2.38$$

En discrétisant la matrice d'évolution du système avec l'hypothèse d'une période d'échantillonnage  $T$  constante, on a :

$$\Phi = e^{-AT} = \begin{pmatrix} 1 & T & (e^{-\alpha T} - 1 - \alpha T) / \alpha^2 \\ 0 & 1 & (1 - e^{-\alpha T}) / \alpha \\ 0 & 0 & e^{-\alpha T} \end{pmatrix} \quad 2.39$$

Souvent la période d'échantillonnage est inférieure à la durée de la manœuvre ( $1/\alpha$ ), dans ce cas l'approximation suivante est souvent utilisée :

$$\Phi \cong \begin{pmatrix} 1 & T & T^2/2 \\ 0 & 1 & T(1-\alpha T/2) \\ 0 & 0 & e^{-\alpha T} \end{pmatrix} \quad 2.40$$

Le cas limite est un cas d'intérêt particulier :

$$\lim_{\alpha T \rightarrow 0} \Phi \cong \begin{pmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{pmatrix} \quad 2.41$$

C'est la matrice newtonienne du modèle à accélération constante [45].

### 2.6.3 Modèle de virage (CT)

Un modèle pour décrire des virages a été proposé pour les mouvements des véhicules aériens. C'est un modèle non-linéaire sous la désignation de modèle « Coordinated Turn (CT) » [45].

Soit  $X_t = (x, y, \dot{x}, \dot{y})^T$  où  $x$  et  $y$  sont les coordonnées cartésiennes de la position.  $\dot{x}, \dot{y}$  sont les composantes de la vitesse. Si nous supposons une vitesse constante,  $v = \sqrt{\dot{x}^2 + \dot{y}^2}$  et un tau x de virage constant  $\Omega = \dot{\psi}$  où nous avons :

$$\begin{cases} \dot{x} = v \cos \psi \\ \dot{y} = v \sin \psi \end{cases} \quad 2.42$$

Les composantes de l'accélération avec  $\dot{\psi} = \Omega$  sont :

$$\begin{cases} \ddot{x} = \frac{d}{dt} \dot{x} = -v\Omega \sin \psi = -\Omega \dot{y} \\ \ddot{y} = \frac{d}{dt} \dot{y} = v\Omega \cos \psi = \Omega \dot{x} \end{cases} \quad 2.43$$

L'équation d'état peut s'exprimer par :

$$\ddot{X}(t) = \frac{d}{dt} \begin{pmatrix} x \\ \dot{x} \\ y \\ \dot{y} \end{pmatrix} = \begin{pmatrix} \dot{x} \\ -\Omega \dot{y} \\ y \\ \Omega \dot{x} \end{pmatrix} \quad 2.44$$

En discrétisant le système on trouve :

$$X_{t+1} = \begin{pmatrix} 1 & \frac{\sin \Omega T}{\Omega} & 0 & -\frac{1 - \cos \Omega T}{\Omega} \\ 0 & \cos \Omega T & 0 & -\sin \Omega T \\ 0 & \frac{1 - \cos \Omega T}{\Omega} & 1 & \frac{\sin \Omega T}{\Omega} \\ 0 & \sin \Omega T & 0 & \cos \Omega T \end{pmatrix} X_t + Bv_t \quad 2.45$$

## 2.7 Conclusion

Dans cette partie nous avons cité les différents filtres utilisés pour l'estimation d'état, commençant par le filtre de Kalman standard qui est conçu pour estimer les états des modèles linéaire, puis on a étudié l'extension du filtre de Kalman pour les modèles non linéaires, qui consiste à linéariser les modèle non linéaires autour des points de fonctionnement .

## **CHAPITRE 3**

### **APPROCHES A MODELES MULTIPLES POUR L'ESTIMATION DU MOUVEMENT**

#### 3.1 Introduction

La discipline de la poursuite de cibles occupe une grande place dans la littérature, incorporant l'estimation d'état, les techniques d'estimations à modèles multiples, les méthodes d'associations des 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 standard peut être limité. Les structures alternatives utilisant plusieurs filtres de Kalman en parallèle ont montrées un succès dans ce problème. Nous allons présenter dans ce chapitre, les différentes techniques à modèles multiples utilisées dans le domaine de poursuite.

#### 3.2 Estimation adaptative à modèles multiples

Généralement lors de la poursuite de cibles, deux classes de modèles sont considérés, à savoir : manœuvrant et non manœuvrant. Les modèles non manouvants sont employés pour exploiter le fait que la plupart des avions (civiles) volent le long de chemins droits (trajectoires rectilignes) le plus de temps. Une telle connaissance introduit la certitude intrinsèque dans le problème d'estimation, qui peut être employé pour réduire la largeur de bande du filtre de poursuite et pour augmenter considérablement la précision des estimations d'état. Cependant dans des applications militaires, les avions peuvent effectuer une variété de manœuvres, rendant nécessaire l'incorporation des modèles manœuvrants dans les systèmes de poursuite pour décrire convenablement le mouvement de la cible.

Deux types de stratégies sont utilisés pour s'adapter aux changements des modèles dynamiques. La première est basée sur l'utilisation de la mesure

pour l'estimation des paramètres inconnus de la manœuvre, cependant elle présente l'inconvénient d'une adaptation lente lors de la manœuvre.

Quant à la deuxième, elle est basée sur l'utilisation d'une banque parallèle d'estimateurs, permettant ainsi de pallier à l'inconvénient de la première approche. Chacun des estimateurs est accordé à une condition de fonctionnement différente, leurs sorties sont combinées dans une estimation moyenne pondérée basée sur l'exécution apparente de chaque filtre élémentaire [39].

### 3.3 Approches d'estimation à modèles multiple pour la poursuite de cibles

Toutes les techniques à modèles multiples, partagent la même architecture de base, et diffèrent seulement de la façon avec laquelle les poids des modèles sont calculés, et dans le mélange d'estimations des modèles conditionnés entre les cycles de traitement. Nous allons présenter brièvement les différentes approches modèles multiples existantes [39].

Nous supposons dans ce qui suit que chaque filtre basé sur le modèle  $M_j$  a pour sorties :

- L'estimé de l'état du modèle  $\hat{X}_j$
- La covariance associée  $P_j$
- La fonction de vraisemblance du modèle  $\Lambda_j$

#### 3.3.1 Approche à modèles multiples (cas de non changement de modèles)

Dans cette approche, il est supposé que les cibles peuvent suivre un modèle de mouvement parmi  $r$  possibles. L'algorithme de cette dernière, se déroule selon les phases suivantes :

- Calcul des probabilités des modèles

Dans ce calcul aucun argument du temps n'est exigé, car on assume que le modèle ne change pas avec le temps, La probabilité à posteriori que le modèle  $j$  étant correct, connaissant l'histoire de mesures jusqu'à l'instant  $k$  est représentée par :

$$\mu_j(k) = P\{M_j | Z^k\} \quad 3.1$$

➤ Calcul des estimés combinés

L'estimation de la moyenne conditionnelle du système est calculée comme une moyenne pondérée des estimées élémentaire de chaque filtre, en utilisant les probabilités des modèles  $\mu_j(k)$  comme poids :

$$\hat{x}(k|k) = \sum_{j=1}^r \mu_j(k) \hat{x}_j(k|k) \quad 3.2$$

La covariance de cette estimation peut également être formulée en utilisant une moyenne pondérée, mais la considération du terme de correction induit par le décalage entre les différentes estimées issu de la formulation gaussienne des densités de ces estimées, cette dernière est donnée par:

$$P(k|k) = \sum_{j=1}^r \mu_j(k) \left\{ P_j(k|k) + [\hat{x}_j(k|k) - \hat{x}(k|k)] [\hat{x}_j(k|k) - \hat{x}(k|k)]^T \right\} \quad 3.3$$

où  $\hat{x}_j$ ,  $P_j$  sont respectivement l'état et la covariance estimés associés au filtre  $j$ .

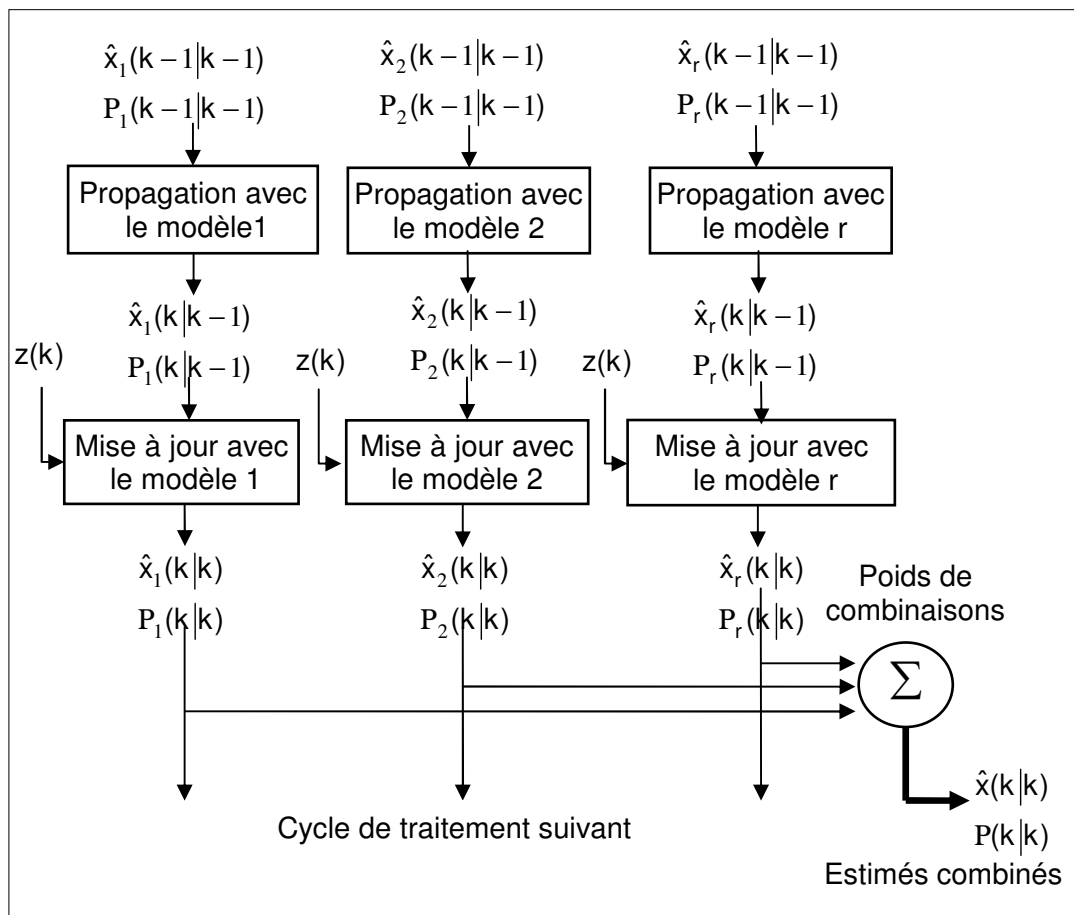


Figure 3.1 : Schéma fonctionnel de l'algorithme d'estimation à modèles multiples fixes (cas de non changement de modèles)

La figure 3-1 montre la structure générale de l'algorithme modèle multiple pour des modèles fixes. Les estimées des modèles conditionnées par chaque filtre élémentaire à chaque cycle de traitement sont passées directement dans le même filtre au cycle de traitement suivant, car on suppose que le modèle en vigueur ne change pas avec le temps. L'estimation combinée globale est calculée comme moyenne pondérée des estimées des différents filtres [39].

### 3.3.2 Approche à modèles multiples (cas de changement de modèle)

Trois principaux algorithmes ont été proposés. Ils diffèrent par leur complexité et leur efficacité.

#### ■ Estimateur Pseudo-Bayésien Généralisé de Premier Ordre (GPB1)

Ce dernier utilise les estimées combinées globales de l'instant précédent comme entrées communes pour tous les filtres. Donc le nombre d'estimées au début de chaque cycle de l'algorithme est  $N_e=1$  et le nombre de filtre  $N_f=r$ . La structure de l'algorithme GPB-1 est illustrée par la figure 3-2.



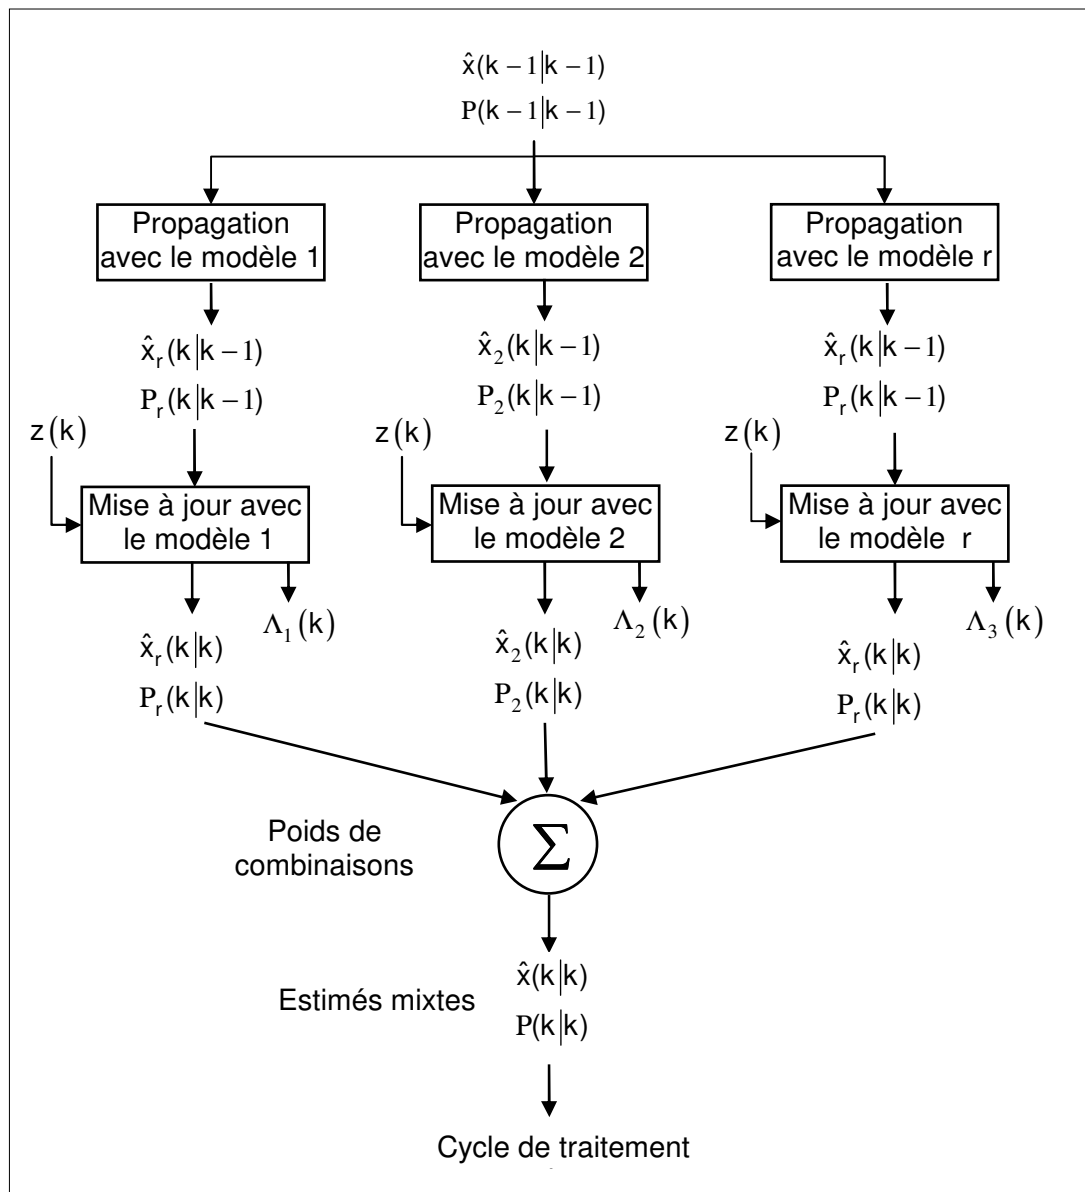


Figure 3.2 : Schéma descriptif de l'algorithme GPB-1

A chaque cycle de traitement, les sorties de tous les filtres, sont fusionnées dans un estimé de  $x$  et de  $P$  en utilisant les probabilités des modèles. Elles seront par la suite employées comme entrée de chacun des filtres au prochain cycle de traitement, fournissant une approximation très brute du système optimal.

#### ■ Estimateur Pseudo-Bayésien Généralisé de Deuxième Ordre (GPB2)

Le nombre de filtres nécessaires pour son implémentation est égal au nombre de modèles considérés à la puissance deux. Il présente de bonnes performances accompagnées d'une complexité calculatoire, qui peut être évitée grâce au

troisième algorithme. Le nombre d'estimées au début de chaque cycle de l'algorithme est  $N_e = r$ , et le nombre de filtre  $N_f = r^2$ . La structure de l'algorithme GPB-2 est illustrée par la figure 3-3.

Comparé à la structure de l'algorithme GPB-1 représentée sur la figure (3-2), l'algorithme GPB-2 utilise  $r^2$  filtres, ainsi il peut maintenir  $r$  estimations et propage chaque estimation avec chacun des  $r$  filtres à chaque intervalle de traitement [39].

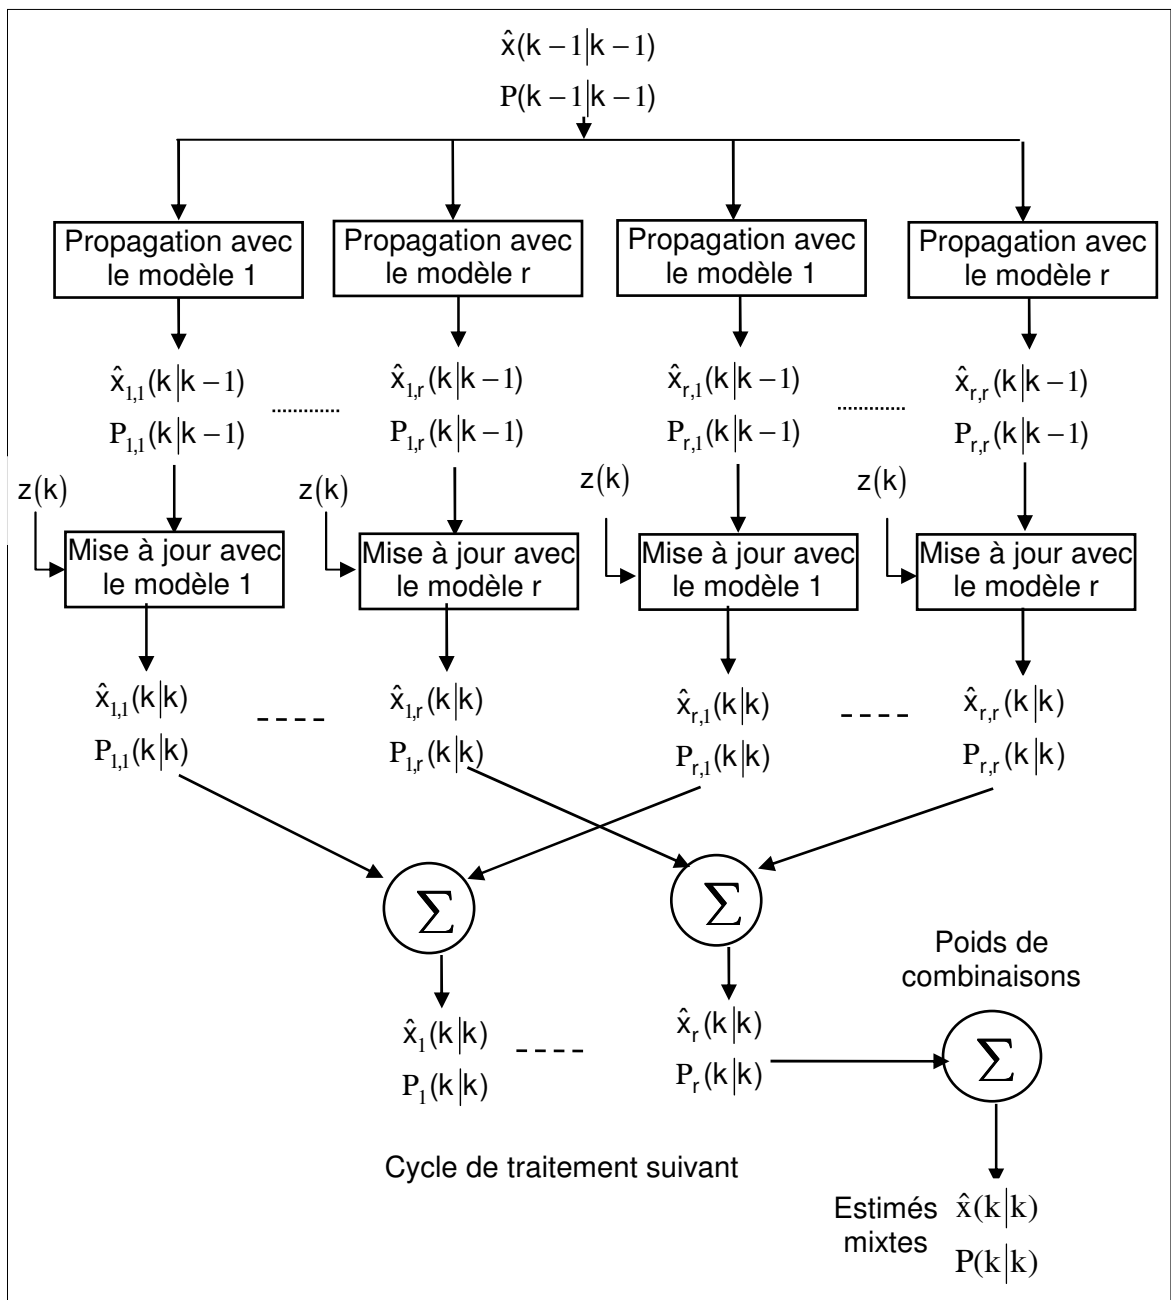


Figure 3.3 : Schéma descriptif de l'algorithme GPB-2

### ■ Estimateur Modèles Multiples Interagissant (IMM)

Le problème d'estimation dans la poursuite de cibles manoeuvrantes implique des changements rapides dans la dynamique du système. Ces changements sont dus à des séquences inconnues. Pour effectuer une estimation précise, plusieurs modèles sont utilisés, chacun est adopté pour décrire un comportement spécifique possible de la cible. Une question importante pour l'application de l'estimateur multiples modèles est de réduire le nombre d'hypothèses, c'est-à-dire les combinaisons possibles des estimées au début de chaque cycle de l'algorithme avec les différents filtres, ainsi il réalise une exécution comparable à l'estimateur GPB-2 à l'aide seulement de  $r$  filtres élémentaires, plutôt que  $r^2$ . La structure de l'algorithme IMM est  $(N_e; N_f) = (r; r)$ . La figure suivante illustre la structure de l'algorithme IMM :

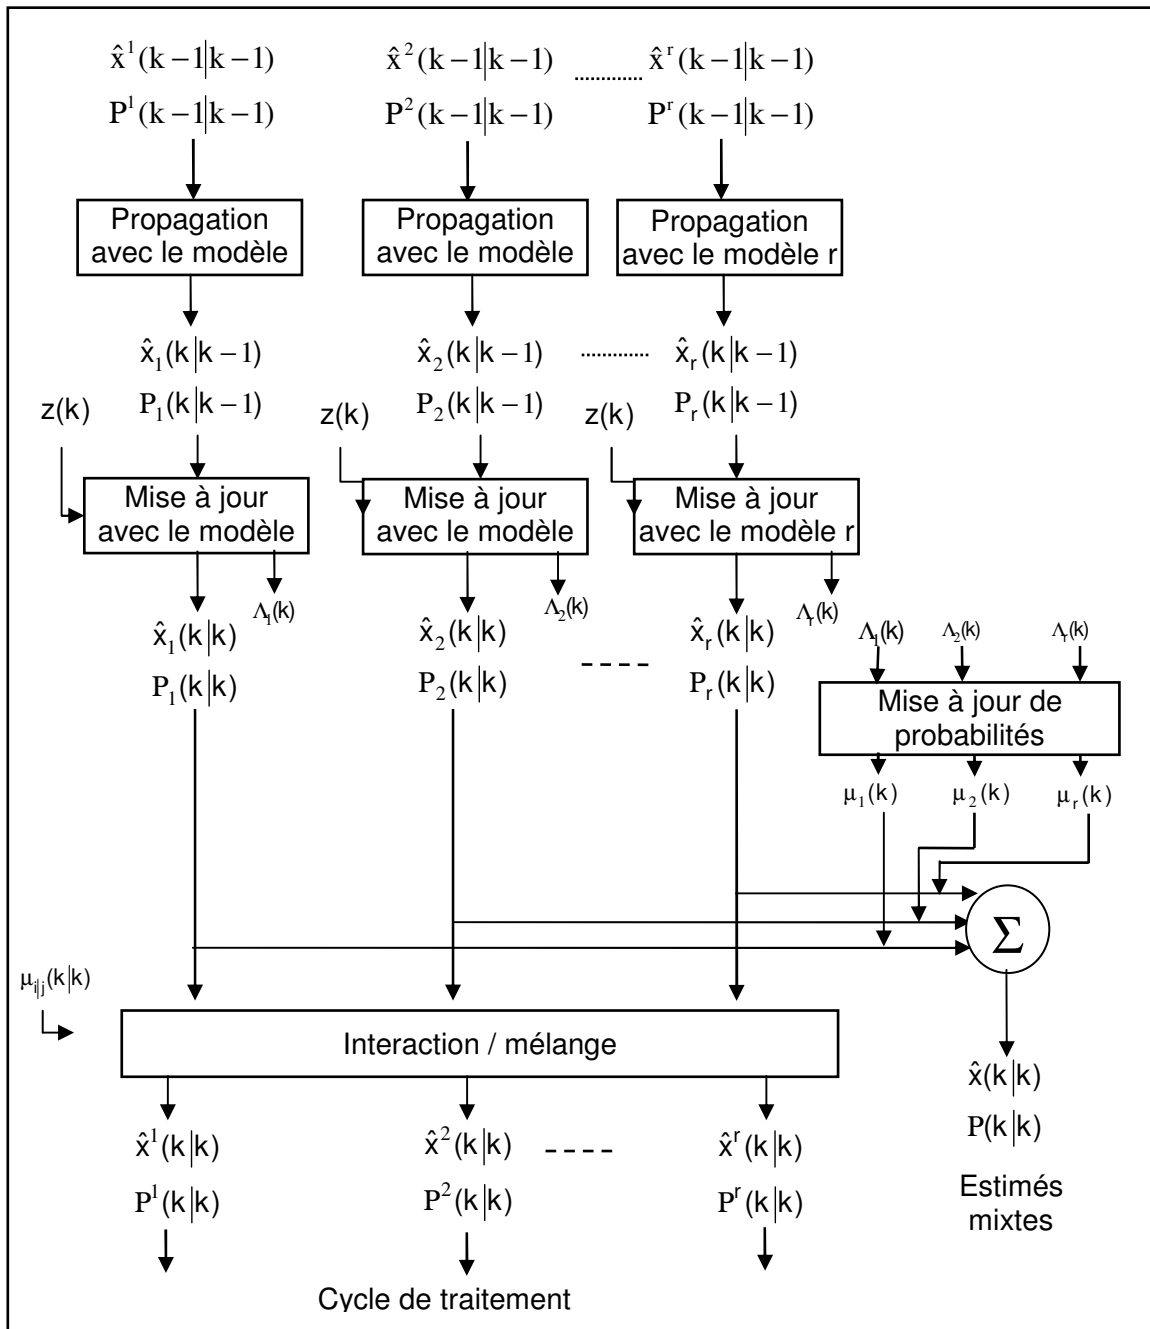


Figure 3.4 : Schéma descriptif de l'algorithme IMM

Selon les techniques à modèles multiples précédentes, l'estimation combinée est calculée à chaque cycle de traitement pour donner la sortie de l'estimateur. La structure est très semblable à celles des modèles fixes (cas de non changement de modèles) représentée sur la figure (3.1). Il y a  $r$  filtres, dont chacun est fourni avec une entrée différente. Cependant, plutôt que d'injecter 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 du modèle en vigueur. D'une autre façon, l'entrée du filtre assorti du modèle  $i$  est obtenue par une interaction des  $r$  filtres, qui consiste à mélanger les estimés  $\hat{x}_j = (k | k)$  avec les pondérations  $\mu_{ij} = (k | k)$ , appelées probabilités mixtes [39].

### ■ L'algorithme IMM

Dans le paragraphe qui suit nous allons illustrer les différentes étapes de la technique IMM.

Le système observé évolue par sélection d'un modèle parmi  $r$  modèles linéaires avec des basculements d'un modèle à un autre.

Soit  $j$  l'indice du modèle,  $j \in \{1, r\}$ . Nous supposant des modèles d'état de la forme :

$$\begin{cases} x(k) = F_j(k)x(k-1) + w(k-1) \\ z(k) = H_j(k)x(k) + v(k) \end{cases} \quad 3.4$$

où  $x(k)$  est le vecteur d'état à l'instant  $k$ ,  $z(k)$  est le vecteur de mesure,  $F_j(k)$  est la matrice d'état,  $H_j$  est la matrice de mesure,  $w(k)$  et  $v(k)$  sont respectivement le bruit d'état et le bruit de mesure tel que leur covariance donnée par :

$$\begin{aligned} E[w(k)w(i)^T] &= \begin{cases} Q(k) & \text{pour } k=i \\ 0 & \text{pour } k \neq i \end{cases} \\ E[v(k)v(i)^T] &= \begin{cases} R(k) & \text{pour } k=i \\ 0 & \text{pour } k \neq i \end{cases} \\ E[w(k)v(i)^T] &= 0 \quad \forall k, i \end{aligned} \quad 3.5$$

#### ➤ Calcul de probabilités mixtes

Soit  $p_{ij}$  la probabilité de transition du modèle  $j$  vers le modèle  $i$ . La probabilité d'utilisation du modèle  $j$  à l'instant  $k-1$  est  $\mu_j(k-1)$ , la probabilité prédite est

$$\bar{c}^j = \sum_{i=1}^r p_{ij} \mu_i(k-1) \quad 3.6$$

A chaque nouvelle itération, les estimations calculées précédemment pour chaque modèle sont fusionnées. Nous calculons ainsi  $\mu_{ij}$  la probabilité conditionnelle d'utilisation d'un modèle  $j$  sachant que nous utilisons un modèle  $i$  :

$$\mu_{ij}(k-1) = \frac{p_{ij}\mu_i(k-1)}{\bar{c}_j} \quad 3.7$$

➤ Mélange (mixing)

L'estimation de l'état fusionné pour le modèle  $j$  est donnée par la relation (3.8). Celle de la covariance de l'état par l'équation (3.9) :

$$\hat{x}_{0j}(k-1) = \sum_{i=1}^r \hat{x}_i(k-1/k-1)\mu_{ij}(k-1) \quad 3.8$$

$$P_{0j}(k-1) = \sum_{i=1}^r \mu_{ij}(k-1) \left[ P_i(k-1) + (V^{ij})(V^{ij})^T \right] \quad 3.9$$

avec :  $V^{ij} = \hat{x}_i(k-1/k-1) - \hat{x}_{0j}(k-1)$

Chaque estimation fusionnée est mise à jour avec la nouvelle mesure  $z(k)$ , disponible à l'instant  $k$ . Les équations de prédiction sont alors :

$$\begin{cases} \text{état : } \hat{x}_j(k/k-1) = F_j \hat{x}_{0j}(k-1) \\ \text{covariance : } P_j(k/k-1) = F_j P_{0j}(k-1/k-1) F_j^T + Q_j \end{cases} \quad 3.10$$

La mesure résiduelle est :  $v_j(k) = z(k) - H_j \hat{x}_j(k/k-1)$

L'estimation de sa matrice de covariance est :

$$s_j(k) = H_j P_j(k/k-1) H_j^T + R_j \quad 3.11$$

L'expression du gain est :

$$K_j(k) = P_j(k/k-1) H_j^T / s_j(k)$$

3.12

Et les estimations sont :

$$\begin{cases} \text{état : } \hat{x}_j(k/k) = \hat{x}_j(k/k-1) + K_j(k) v_j(k) \\ \text{covariance : } P_j(k/k) = P_j(k/k-1) - K_j(k) H_j P_j(k/k-1) \end{cases} \quad 3.13$$

➤ Mise à jour de probabilité du modèle

Il est généralement nécessaire de mettre à jour les probabilités des différents modèles. Elles sont recalculées à partir de leurs probabilités prédites et

de leurs fonctions de vraisemblance. Pour un modèle  $j$  la fonction de vraisemblance est donnée, dans un cas gaussien, par :

$$\Lambda_j(k) = \frac{1}{\sqrt{2\pi|S_j(k)|}} \exp\left(-\frac{1}{2}(v_j(k))^T (S_j(k))^{-1} (v_j(k))\right) \quad 3.14$$

Il en résulte la probabilité  $\mu_j$  du modèle  $j$  :

$$\mu_j(k) = \frac{1}{c} \Lambda_j(k) \bar{c}_j \quad 3.15$$

avec :

$$c = \sum_{j=1}^r \Lambda_j(k) \bar{c}_j \quad 3.16$$

➤ Combinaison des états estimés et covariances

Les estimations globales de l'état et de la covariance sont :

$$\begin{cases} \hat{x}(k/k) = \sum_{j=1}^r \hat{x}_j(k/k) \mu_j(k) \\ P(k/k) = \sum_{j=1}^r \mu_j(k) \left[ P_j(k/k) + [\hat{x}_j(k/k) - \hat{x}(k/k)] [\hat{x}_j(k/k) - \hat{x}(k/k)]^T \right] \end{cases} \quad 3.17$$

### 3.4 Conclusion

Ce chapitre a été consacré à une présentation succincte des différentes approches d'estimation à modèle multiple généralement utilisées. Ensuite nous avons décrit l'algorithme interactif à modèle multiples (IMM) à base de filtre de Kalman dont nous allons analyser les performances.

## **CHAPITRE 4**

### **LES MESURES HORS SEQUENCE**

#### 4.1 Introduction

Le pistage de cibles dynamiques comporte une étape de traitement des mesures qui rassemble et traite les données fournies par une ou plusieurs sources. En raison de l'aspect temporel de l'opération de pistage, l'ordre chronologique des mesures prend toute son importance.

Dans plusieurs applications, où la plupart sont à sources multiples, il peut y avoir des délais entre l'instant où la mesure est effectuée dans l'environnement et l'instant où elle est reçue et traitée par le système de pistage. Il se peut que le retard soit assez grand pour qu'une mesure effectuée à un temps donné arrive au système de pistage après que la piste d'une cible ait déjà été mise à jour avec une ou plusieurs mesures plus récentes. Une mesure ainsi retardée est désignée sous le nom de Mesure Hors Séquence (MSH), tiré de l'anglais "Out-Of-Sequence Measurements" (OOSM).

La plupart des solutions à ce problème sont basées sur le concept de retrodiction, cette méthode utilise la projection vers l'arrière de l'état courant estimé afin d'incorporer les MHS.

Nous allons présenter dans ce chapitre quelques notions sur les mesures hors séquences ce qu'on appelle OOSM utilisées dans l'algorithme (BL1) que nous avons choisis de présenter, ensuite nous décrirons en détails l'algorithme IMM-BL1 qui fait l'objet de notre étude.

#### 4.2 Les origines des mesures hors séquence (OOSM)

Au cours de ses trois décennies de développement, le radar indicateur de cible mobile terrestre (GMTI) a démontré sa puissance de surveillance et sa capacité de reconnaissance dans des nombreuses applications militaires. Son



habilité à fournir à chaque instant (en temps voulu) des informations détaillées est critique dans un champ de bataille [25].




Figure 4.1 : L'architecture de poursuite multicapteurs

Dans un proche avenir, une opération de surveillance pourra inclure un réseau de plates-formes GMTI. Chaque radar GMTI fonctionnant sous plusieurs modes, incluant un vaste secteur de recherche. Ce réseau de radar GMTI fournira une quantité des données sans précédent sur un grand nombre de cibles appartenant à de petites et grandes unités ennemies dans la région surveillée. Ce réseau de radars GMTI peut apporter à son utilisateur un type d'informations dont la valeur et l'importance militaire est égale à celle de l'imagerie satellitaire.

Comme il y a des milliers d'objets dans une région de surveillance, un grand effort de poursuite est nécessaire pour corréler les mesures radar aux trajectoires de cibles. Entre-temps, dans les conditions de combat, les mesures des multiples plates-formes ne seront pas synchronisées, parce que chaque plate-forme a sa propre fréquence de mesure et le réseau de communication ne peut pas garantir la fourniture des mesures dans le temps. Inévitablement, les mesures asynchrones vont rendre l'ordre des mesures incertain, ce qui crée le phénomène des mesures hors séquence (Out Of Séquence 'OOS') au niveau de traqueur central (central tracker) [25].

Deux problèmes importants doivent être considérés dans le traitement (OOSM) :

- Dans un filtrage de poursuite mono-cible (figure 4.2) : le problème de l'estimation d'état de la cible par un ensemble de mesures des capteurs.




Figure 4.2 : poursuite mono-cible multi-capteurs

- Dans un système de poursuite multi-cibles multi-capteurs (figure 4.3): l'association des données (problème d'association des mesures des capteurs aux trajectoires).

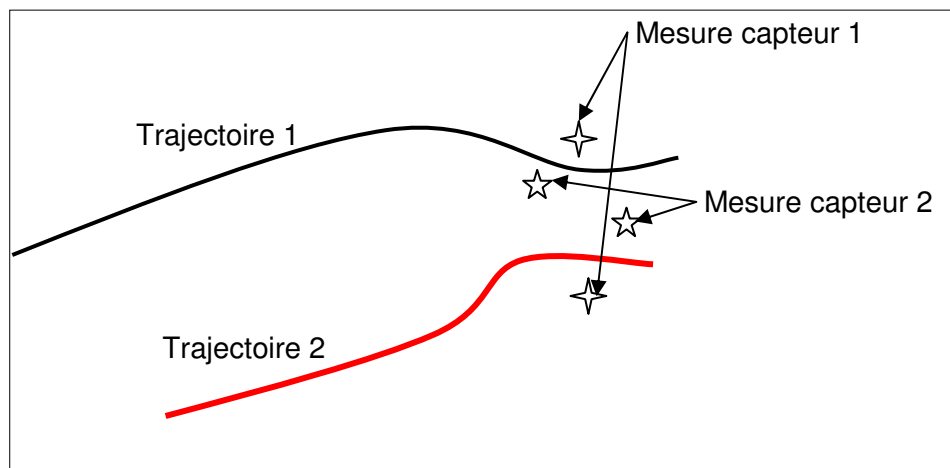


Figure 4.3 : Poursuite multi-cibles multi-capteurs

#### 4.3 Principe de traitement des mesures hors séquence

Plusieurs raisons peuvent expliquer le phénomène OOS (hors séquence) dans un réseau de fusion centralisé. L'une des principales raisons réside dans la différence des retards dans l'acheminement de l'information dans les réseaux de communication [25].

La figure (4-4) montre deux scénarios de fusion centralisée disposant chacun de deux capteurs.

Dans le scénario de la figure (4-4-a), les capteurs A et B fonctionnent à la même fréquence d'échantillonnage, mais possèdent des retards de réseau différents. En pointillés, nous avons représenté la situation dans laquelle les retards de réseau seraient identiques pour les deux capteurs. Dans le scénario de la Figure (4-4-b), les capteurs A et B ont des fréquences d'échantillonnage différentes [25].

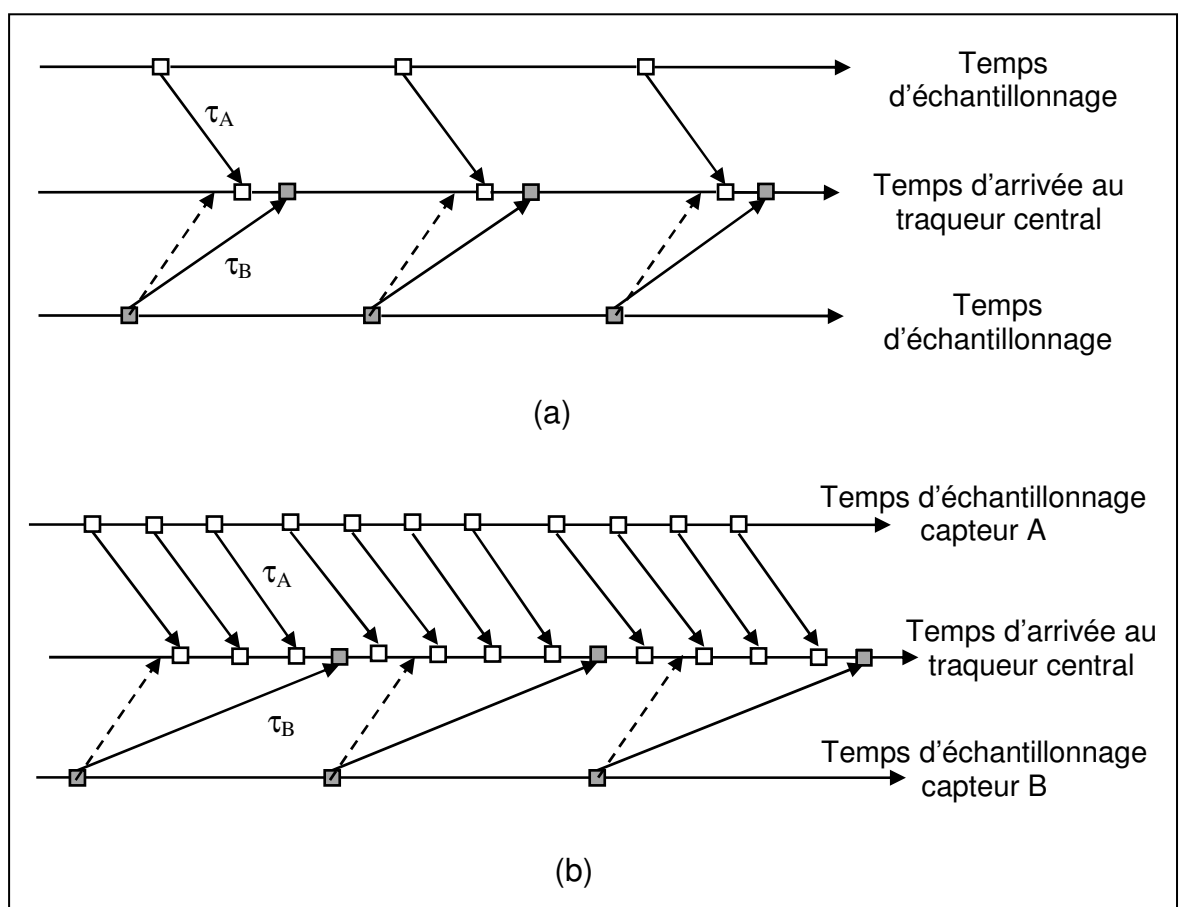


Figure 4.4 : Deux scénarios de fusion centralisée en cas de production de phénomène OOS (Out Of Séquence)

On supposera qu'à chaque mesure, sera joint un indicateur de temps (time stamp) indiquant l'instant (le temps) pendant lequel la mesure a été prise. Nous supposons que le capteur possédant le retard de réseau le plus petit sera considéré comme le capteur arrivant dans les délais (capteur A dans la figure 4.4)

et ses indicateurs de temps seront utilisés comme «instants d'échantillonnage primaires ». La mesure du capteur possédant le retard de réseau le plus grand (capteur B dans la figure 4.2), sera considéré comme mesure hors séquence (OOSM), c'est la mesure ayant l'indicateur de temps le moins récent et apparaissant après que la mesure courante ait été traitée [25].

L'indicateur de temps de la mesure hors séquence peut se situer dans l'intervalle d'une période d'échantillonnage de l'instant courant (scénario (a)) ou se situer plusieurs périodes d'échantillonnage au delà de l'instant courant (scénario (b)) [25].

L'objectif du filtrage par utilisation des mesures hors séquence est d'intégrer ces mesures hors séquence dans l'estimation actuelle afin d'améliorer l'exactitude des résultats de la poursuite.

Il existe deux manières d'incorporer les mesures hors séquences dans le système de poursuite : de manière séquentielle et de manière non séquentielle.

#### ■ Implémentation séquentielle

L'implémentation séquentielle nécessite le retraitement de toutes les anciennes mesures en incluant la mesure hors séquence comme le montre la figure 4-5.

Cette implémentation est optimale. Toutefois, le retraitement des anciennes mesures entraîne un gaspillage des ressources de calcul (saturation du calculateur) [25].

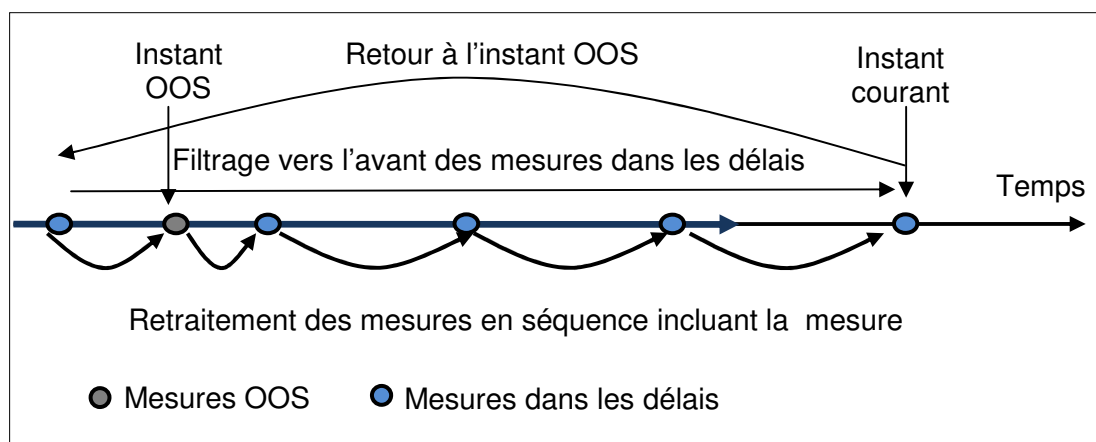


Figure 4.5 : Le filtrage OOS séquentiel

### ■ Implémentation non séquentielle

Dans l'implémentation non séquentielle, on ne traite pas les anciennes mesures. Le schéma non séquentiel a trois composantes:

- Le filtrage vers l'avant (forward) des mesures arrivées dans les délais,
- Retour en arrière de l'instant courant à l'instant où s'est produite la mesure hors séquence. Cette phase de retour en arrière s'appelle rétrodiction,
- Mettre à jour l'estimation actuelle avec l'OOSM.

Ceci est illustré dans la figure 4-6.

Bien que l'implémentation non-séquentielle soit plus efficace que l'implémentation séquentielle lorsqu'elle est appliquée à l'approche à modèles multiples, la charge de calcul reste encore assez élevée. En outre, les deux implémentations séquentielle et non séquentielle nécessitent le stockage de données (estimations, covariance, etc.). Par conséquent, le problème de la mémoire est un point important dans la conception du filtrage des mesures hors séquence [25].

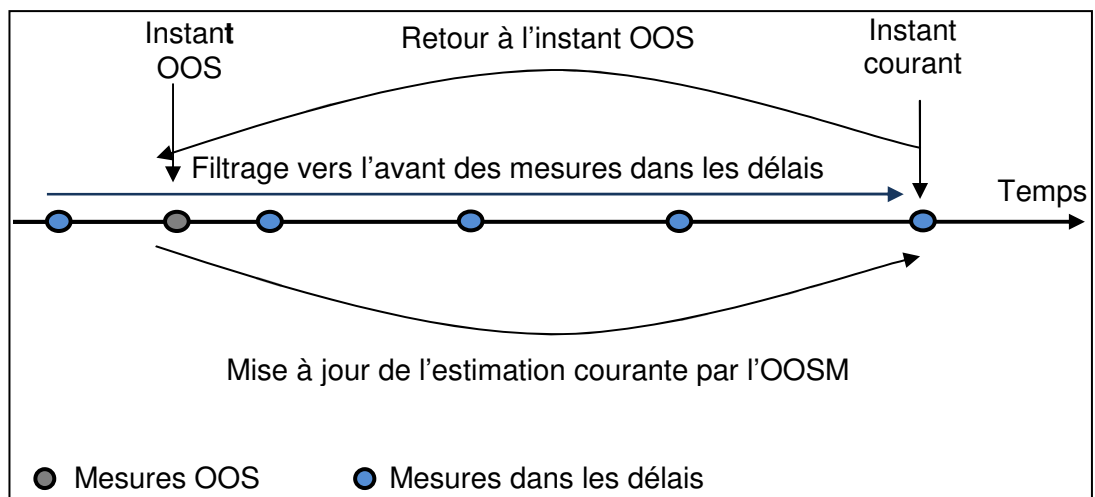


Figure 4.6 : Le filtrage OOS non séquentiel

#### 4.4 OOSM à un pas de retard

Dans ce type de problème, le retard de la mesure hors séquence est inférieur à une période d'échantillonnage, c'est-à-dire que l'instant  $\tau$  de la réalisation de la mesure OOSM est tel que :

$$k-1 \leq \kappa < k$$

Ceci est illustré dans la figure (4-7).  $\kappa$  est la notation discrète de  $\tau$ .




Figure 4.7 : OOSM à un pas de retard

#### 4.4.1 Formulation du problème

Le vecteur d'état du système est supposé évoluer de  $t_{k-1}$  à  $t_k$  en accord avec l'expression suivante [3] :

$$x(k) = F(k, k-1)x(k-1) + v(k, k-1) \quad 4.1$$

$F(k, k-1)$  est la matrice de transition d'état de  $t_k$  à  $t_{k-1}$ .

$v(k, k-1)$  est le bruit d'état dans l'intervalle  $t_k$  à  $t_{k-1}$ .

L'instant  $\tau$  où s'est effectuée l'OOSM est tel que :

$$k-1 \leq \kappa < k \quad 4.2$$

L'équation de mesure est donnée par :

$$z(k) = H(k)x(k) + w(k) \quad 4.3$$

avec les hypothèses standards sur les bruits  $v$  et  $w$  à moyennes nulles et de covariances :

$$Q(k, j) = E[v(k, j)v(k, j)^T] \quad R(k) = E[w(k)w(k)^T] \quad 4.4$$

et mutuellement incorrélés.

On peut écrire l'équation (4.1) sous la forme suivante :

$$x(k) = F(k, \kappa)x(\kappa) + v(k, \kappa) \quad 4.5$$

On peut inverser l'équation (4.5) en écrivant la forme suivante :

$$x(\kappa) = F(\kappa, k)[x(k) - v(k, \kappa)] \quad 4.6$$

où  $F(\kappa, k) = F(k, \kappa)^{-1}$  est la matrice de transition inverse.

Le problème est comme suit. A l'instant  $t = t_k$ , nous avons :

$$\begin{aligned}\hat{x}(k|k) &= E[x(k) | Z^k] \\ P(k|k) &= \text{cov}[x(k) | Z^k]\end{aligned}\quad 4.7$$

avec l'ensemble des mesures à l'instant  $t_k$  données par :

$$Z^k = \{z(i)\}_{i=1}^k \quad 4.8$$

L'équation de mesure à l'instant  $\kappa$  s'écrit :

$$z(\kappa) = z(\tau) = H(\kappa)x(\kappa) + w(\kappa) \quad 4.9$$

Nous voulons mettre à jour les estimés de l'état et de la covariance avec la mesure précédente, précisément calculer :

$$x(k|\kappa) = E[x(k) | Z^k] \quad \text{et} \quad P(k|\kappa) = \text{cov}[x(k) | Z^k] \quad 4.10$$

où

$$Z^k = \{Z^k, z(\kappa)\} \quad 4.11$$

représente l'ensemble des mesures à l'instant  $t_k$

L'approche de la résolution du problème comporte les étapes suivantes [3] :

- Rétrodictioin d'état de l'instant courant  $k$  à l'instant  $\kappa$ , en tenant compte du bruit d'état  $z(k, \kappa)$
- Évaluation de la covariance correspondante
- Calcul du gain du filtre pour la mise à jour de l'état  $x(k)$  avec la dernière mesure  $z(\kappa)$
- Mise à jour de l'état estimé  $\hat{x}(k|k)$  pour avoir  $\hat{x}(k|\kappa)$  et calcul de la covariance correspondante.

#### ■ La rétrodictioin d'état

D'après l'équation (4.6), on peut écrire [3] :

$$\begin{aligned}E[x, \kappa | Z^k] &= F(\kappa, k)E[x(k) - v(k, \kappa) | Z^k] \\ &= F(\kappa, k)E[\hat{x}(k|k) - \hat{v}(k, \kappa) | k]\end{aligned}\quad 4.12$$

En outre, l'évaluation de la covariance de la rétrodictioin d'état exige la covariance croisée des deux derniers termes  $x(k)$  et  $v(k, k)$  conditionné sur  $Z^k$ , donné par [3] :

$$y(k) = \begin{bmatrix} x(k) \\ v(k, \kappa) \end{bmatrix} \quad 4.13$$

Pour obtenir  $\hat{y}(k|k)$ , nous utilisons l'équation fondamentale de l'estimation linéaire [2], donné par :

$$\begin{aligned} \hat{y}(k|k) &= \hat{y}(k|k-1) + \text{cov}\{y(k), z(k) | Z^{k-1}\} \\ &\quad \times \left[ \text{cov}\{z(k) | Z^{k-1}\} \right]^{-1} [z(k) - \hat{z}(k|k-1)] \end{aligned} \quad 4.14$$

Implique que :

$$\begin{aligned} \text{cov}\{y(k) | Z^k\} &= \text{cov}\{y(k) | Z^{k-1}\} \\ &\quad - \text{cov}\{y(k), z(k) | Z^{k-1}\} \left[ \text{cov}\{z(k) | Z^{k-1}\} \right]^{-1} \\ &\quad \times \text{cov}\{y(k), z(k) | Z^{k-1}\}, \end{aligned} \quad 4.15$$

Lorsque toutes les variables aléatoires sont conjointement gaussiens, ces équations rendent les moyennes conditionnelles [2]. Sinon les mêmes équations rendent le minimum de l'erreur quadratique moyenne linéaire (LMMSE) estimée [2].

La première covariance de l'équation (4.14) est donnée par :

$$\begin{aligned} \text{cov}\{y(k), z(k) | Z^{k-1}\} \\ = \begin{bmatrix} \text{cov}\{x(k), z(k) | Z^{k-1}\} \\ \text{cov}\{v(k, \kappa), z(k) | Z^{k-1}\} \end{bmatrix} &= \begin{bmatrix} P(k|k-1)H(k)' \\ Q(k, \kappa)H(k)' \end{bmatrix} \end{aligned} \quad 4.16$$

Les autres termes pertinents sont :

$$\text{cov}\{z(k) | Z^{k-1}\} = S(k) = H(k)P(k|k-1)H(k)' + R(k) \quad 4.17$$

est la covariance de l'innovation donnée par:

$$v(k) = z(k) - \hat{z}(k|k-1) \quad 4.18$$

Ainsi, la moyenne conditionnelle du processus de bruit, c'est la partie inférieure de (4.14), partitionné comme dans (4.13) [3]:

$$\hat{v}(k, \kappa | k) = Q(k, \kappa)H(k)'S(k)^{-1}v(k) \quad 4.19$$

En conséquence, la rétrodiction d'état de  $k$  à  $\kappa$  est :



$$\hat{x}(\kappa | k) = F(\kappa, k) \left[ \hat{x}(k | \kappa) - Q(k, \kappa) H(k)' S(k)^{-1} v(k) \right] \quad 4.20$$

La covariance correspondante à l'équation (4.19) est :

$$\begin{aligned} \text{cov}\{v(k, \kappa) | Z^k\} \\ &= Q(k, \kappa) - Q(k, \kappa) H(k)' S(k)^{-1} H(k) Q(k, \kappa) \\ &= P_{vv}(k, \kappa | k) \end{aligned} \quad 4.21$$

et la covariance croisée des deux termes dans l'équation de rétrodiction (4.12) est :

$$\begin{aligned} \text{cov}\{x(k), v(k, \kappa) | Z^k\} \\ &= Q(k, \kappa) - P(k | k-1) H(k)' S(k)^{-1} H(k) Q(k, \kappa) \\ &= P_{xv}(k, \kappa | k) \end{aligned} \quad 4.22$$

Ainsi que :

$$\begin{aligned} \text{cov}\{x(k) | Z^k\} &= P(k | k-1) - P(k | k-1) \times H(k)' S(k)^{-1} H(k) P(k | k-1) \\ &\quad \square P(k | k) \end{aligned} \quad 4.23$$

La combinaison de ce que précède donne la covariance de la rétrodiction d'état (4.20) :

$$\begin{aligned} \text{cov}\{x(\kappa) | Z^k\} \\ &= F(\kappa, k) [\text{cov}\{x(k) | Z^k\} + \text{cov}\{v(k, \kappa) | Z^k\} - \text{cov}\{x(k), v(k, \kappa) | Z^k\} \\ &\quad - \text{cov}\{x(k), v(k, \kappa) | Z^k\}' ] F(\kappa, k)' \\ &= F(\kappa, k) [P(k | k) + P_{vv}(k, \kappa | k) - P_{xv}(k, \kappa | k) - P_{xv}(k, \kappa | k)'] F(\kappa, k)' \\ &= P(\kappa | k) \end{aligned} \quad 4.24$$

Il y a deux solutions à la mise à jour de l'état avec l'OOSM [3] :

- La solution optimale appelé « algorithme A1 »
- La solution sous optimale appelée « algorithme B1 »

Nous allons examiner dans les paragraphes suivants, ces deux solutions.

#### 4.4.2 Algorithme optimal A1

##### ■ Mise à jour optimale de l'estimé de l'état avec l'OOSM

La covariance de la rétrodiction de mesure à l'instant  $\kappa$  est, en utilisant (4.24) [3] :

$$\text{cov}\{z(\kappa) | Z^k\} = S(\kappa) = H(\kappa)P(\kappa | k)H(\kappa)' + R(\kappa) \quad 4.25$$

La covariance entre l'état à l'instant  $k$  et cette mesure (utilisant (4.9) et (4.6)) est :

$$\begin{aligned} \text{cov}\{x(\kappa), z(\kappa) | Z^k\} &= \text{cov}\{x(k), H(\kappa)F(\kappa, k)[x(k) - v(k, \kappa)] + w(\kappa) | Z^k\} \\ &= [P(k | k) - P_{xv}(k, \kappa | k)]F(\kappa, k)'H(\kappa)' \\ &= P_{xz}(k, \kappa | k) \end{aligned} \quad 4.26$$

Ainsi, la mise à jour avec l'OOSM  $z(\kappa)$  de l'état estimé le plus récent  $\hat{x}(k | k)$  est :

$$\hat{x}(k | \kappa) = \hat{x}(k | k) + K(k, \kappa)[z(\kappa) - H(\kappa)\hat{x}(k | k)] \quad 4.27$$

où  $\hat{x}(k | k)$  est donnée par l'équation (4.20) et le gain utilisé dans cette mise à jour est donné par l'équation suivante :

$$K(k, \kappa) = P_{xz}(k, \kappa | k)S(\kappa)^{-1} \quad 4.28$$

La covariance de cette mise à jour de l'estimé de l'état est donnée par :

$$P(k | \kappa) = P(k | k) - P_{xz}(k, \kappa | k)S(\kappa)^{-1}P_{xz}(k, \kappa | k)' \quad 4.29$$

#### ■ Résumé de l'algorithme optimal

– Rétrodition d'état de  $\kappa$  à  $k$  :

$$\hat{x}(\kappa | k) = F(\kappa, k)\left[\hat{x}(k | k) - Q(k, \kappa)H(k)'S(k)^{-1}v(k)\right] \quad 4.30$$

– Covariances associées à la rétrodition d'état :

$$P_{vv}(k, \kappa | k) = Q(k, \kappa) - Q(k, \kappa)H(k)'S(k)^{-1}H(k)Q(k, \kappa) \quad 4.31$$

$$P_{xv}(k, \kappa | k) = Q(k, \kappa) - P(k | k-1)H(k)'S(k)^{-1}H(k)Q(k, \kappa) \quad 4.32$$

$$P(k | k) = P(k | k-1) - P(k | k-1)H(k)'S(k)^{-1}H(k)P(k | k-1) \quad 4.33$$

– Covariance de la rétrodition de l'état :

$$P(\kappa | k) = F(\kappa, k)[P(k | k) + P_{vv}(k, \kappa | k) - P_{xv}(k, \kappa | k) - P_{xv}(k, \kappa | k)']F(\kappa, k)' \quad 4.34$$

– Covariance de la rétrodition de la mesure :

$$S(\kappa) = H(\kappa)P(\kappa | k)H(\kappa)' + R(\kappa) \quad 4.35$$

– Covariance entre l'état à l'instant  $k$  et cette mesure :

$$P_{xz}(k, \kappa | k) = [P(k | k) - P_{xv}(k, \kappa | k)]F(\kappa, k)'H(\kappa)' \quad 4.36$$

– Gain de la mise à jour :

$$K(k, \kappa) = P_{xz}(k, \kappa | k) S(\kappa)^{-1} \quad 4.37$$

– Mise à jour avec l'OOSM  $z(\kappa)$  de l'estimé de l'état :

$$\hat{x}(k | \kappa) = \hat{x}(k | k) + K(k, \kappa) [z(\kappa) - H(\kappa) \hat{x}(\kappa | k)] \quad 4.38$$

– Covariance de la mise à jour de l'estimé de l'état :

$$P(k | \kappa) = P(k | k) - P_{xz}(k, \kappa | k) S(\kappa)^{-1} P_{xz}(k, \kappa | k)' \quad 4.39$$

#### 4.4.3 Algorithme sous-optimal B1

Dans la technique sous-optimale, la rétrodiction du bruit est supposée nulle [3].

La rétrodiction de l'état de  $k$  à  $\kappa$  est donnée par :

$$\hat{x}^B(\kappa | k) = F(\kappa, k) \hat{x}(k | k) \quad 4.40$$

Les covariances associées à la rétrodiction de l'état sont :

$$P_{vv}^B(k, \kappa) = Q(k, \kappa) \quad 4.41$$

$$P_{xv}^B(k, \kappa | k) = Q(k, \kappa) - P(k | k - 1) H(k)' S(k)^{-1} H(k) Q(k, \kappa) \quad 4.42$$

$$P(k | k) = P(k | k - 1) - P(k | k - 1) H(k)' S(k)^{-1} H(k) P(k | k - 1) \quad 4.43$$

La covariance de la rétrodiction de l'état est donnée par :

$$P^B(\kappa | k) = F(\kappa, k) \left[ P(k | k) + P_{vv}^B(k, \kappa | k) - P_{xv}^B(k, \kappa | k) - P_{xv}^B(k, \kappa | k)' \right] F(\kappa, k)' \quad 4.44$$

La covariance de la rétrodiction de la mesure est donnée par :

$$S^B(\kappa) = H(\kappa) P^B(\kappa | k) H(\kappa)' + R(\kappa) \quad 4.45$$

La covariance entre l'état à l'instant  $k$  et cette mesure est calculée par :

$$P_{xz}^B(k, \kappa | k) = \left[ P(k | k) - P_{xv}^B(k, \kappa | k) \right] F(\kappa, k)' H(\kappa)' \quad 4.46$$

Le gain de la mise à jour est :

$$K^B(k, \kappa) = P_{xz}^B(k, \kappa | k) S^B(\kappa)^{-1} \quad 4.47$$

La mise à jour avec l'OOSM  $z(\kappa)$  de l'estimé de l'état la plus récente  $\hat{x}(k | k)$  est :

$$\hat{x}^B(k | \kappa) = \hat{x}(k | k) + K^B(k, \kappa) [z(\kappa) - H(\kappa) \hat{x}^B(\kappa | k)] \quad 4.48$$

La mise à jour de la covariance de l'estimé de l'état est donnée par :

$$P^B(k \setminus \kappa) = P(k \setminus k) - P_{xz}^B(k, \kappa \setminus k) S^B(\kappa)^{-1} P_{xz}^B(k, \kappa \setminus k)' \quad 4.49$$

Les seules différences entre l'algorithme sous optimale B1 et l'algorithme optimal A1 sont les équations (4.40) et (4.41), qui sont des versions simplifiées des équations (4.30) et (4.31), respectivement [3].

#### 4.5 OOSM à l pas de retard

Dans ce type de problème, le retard de la mesure hors séquence est supérieur à une période d'échantillonnage, c'est-à-dire que l'instant  $\tau$  de la réalisation de la mesure OOSM est tel que :

$$k - l \leq \kappa < k - l + 1$$

Notons que  $l=1$  correspond au cas précédent (OOSM à 1 pas de retard).

Ceci est illustré dans la figure 4.8 [25].




Figure 4.8 : OOSM à l pas de retard ( $l=2$ )

##### 4.5.1 Formulation du problème

Le vecteur d'état du système est supposé évoluer de  $t_{k-1}$  à  $t_k$  en accord avec l'expression suivante :

$$x(k) = F(k, k-1)x(k-1) + v(k, k-1) \quad 4.50$$

$F(k, k-1)$  est la matrice de transition d'état de  $t_k$  à  $t_{k-1}$ .

$v(k, k-1)$  est le bruit d'état dans l'intervalle  $t_k$  à  $t_{k-1}$ .

L'instant  $\tau$  où s'est effectuée l'OOSM est tel que :

$$k - l \leq \kappa < k - l + 1$$

L'équation de mesure est donnée par :

$$z(k) = H(k)x(k) + w(k) \quad 4.51$$

avec les hypothèses standards sur les bruits  $v$  et  $w$  à moyennes nulles et de covariances :

$$Q(k, j) = E \left[ v(k, j) v(k, j)^T \right] \quad R(k) = E \left[ w(k) w(k)^T \right] \quad 4.52$$

et mutuellement incorrélés.

On peut écrire l'équation (4.50) sous la forme suivante :

$$x(k) = F(k, \kappa) x(\kappa) + v(k, \kappa) \quad 4.53$$

On peut inverser l'équation (4.53) en écrivant la forme suivante :

$$x(\kappa) = F(\kappa, k) [x(k) - v(k, \kappa)] \quad 4.54$$

où  $F(\kappa, k) = F(k, \kappa)^{-1}$  est la matrice de transition inverse.

Le problème est comme suit. A l'instant  $t = t_k$ , nous avons :

$$\hat{x}(k | k) = E \left[ x(k) | Z^k \right] \quad 4.55$$

$$P(k | k) = \text{cov} \left[ x(k) | Z^k \right]$$

avec l'ensemble des mesures à l'instant  $t_k$  données par :

$$Z^k = \{z(i)\}_{i=1}^k \quad 4.56$$

L'équation de mesure à l'instant  $\kappa$  s'écrit :

$$z(\kappa) = z(\tau) = H(\kappa) x(\kappa) + w(\kappa) \quad 4.57$$

Nous voulons mettre à jour les estimés de l'état et de la covariance avec la mesure précédente, précisément calculer :

$$x(k | \kappa) = E \left[ x(k) | Z^k \right] \quad \text{et} \quad P(k \setminus \kappa) = \text{cov} \left[ x(k) | Z^k \right] \quad 4.58$$

Où

$$Z^k = \{Z^k, z(\kappa)\} \quad 4.59$$

représente l'ensemble des mesures à l'instant  $t_k$  [7].

#### 4.5.2 L'approche de résolution du problème

L'approche la plus connue, utilisée pour résoudre ce problème consiste à se ramener au problème à un pas de retard.

L'approche qui permettra de résoudre le problème de l pas de retard comme un problème à 1 pas de retard est de définir une mesure équivalente à l'instant  $k$  qui remplace toutes les mesures :

$$Z_{k+l+1}^k = \{z(k-l+1), \dots, z(k)\} \quad 4.60$$

Dans ces conditions, la mesure OOSM tombe dans l'intervalle suivant :

$$T_l = [t_{k-l}, t_k] \quad 4.61$$

De cette manière, l'OOSM de plusieurs retards (L pas) devient un OOSM d'un seul retard (un pas) et toutes les techniques optimale [4] « algorithme A» et approximative « algorithme B» peuvent être utilisés pour la mise à jour dans une seule étape [7].

Les algorithmes résolvent dans une seule étape le problème de plusieurs OOSM s'appel BI1, AI1 (dans notre mémoire on s'intéresse au BI1).

La mesure équivalente à l'instant k est définie par l'équation suivante :

$$z^*(k) = H^*(k)x(k) + w^*(k) \quad 4.62$$

avec un bruit blanc à moyenne nulle et de la covariance suivante :

$$E[w^*(k)w^*(k)'] = R^*(k) \quad 4.63$$

Dans l'ordre on peut utiliser un filtre de Kalman standard (KF) mis à jour par la mesure équivalente  $z^*(k)$  et  $\hat{x}^*(k|k) = \hat{x}(k|k)$ , c'est-à-dire même estimation (et covariance) obtenue lorsque les mesures (4.60) sont utilisés de façon séquentielle dans le KF,  $w^*(k)$  est on supposé orthogonal sur le processus des bruits dans l'intervalle (4.61). Cependant, il s'agit d'une approximation et nous évaluons son effet sur l'algorithme résultant [7].

A l'instant k, nous avons une estimation d'état  $\hat{x}(k|k)$  et sa covariance  $P(k|k)$ . Pour calculer  $R^*(k)$ , il faut faire la mise à jour équivalente de la prédiction de "dernier" instant  $t_{k-l}$  selon (4.61) rend comme la covariance  $P(k|k)$  [2].

La covariance de la mesure équivalente est donnée par :

$$\begin{aligned} P^*(k|k)^{-1} &= P(k|k-l)^{-1} + H^*(k)'R^*(k)^{-1}H^*(k) \\ &= P(k|k)^{-1} \end{aligned} \quad 4.64$$

avec :

$$P(k|k-l-1) = F(k,k-l)P(k-l|k-l)F(k,k-l)' + Q(k,k-l) \quad 4.65$$

On peut choisir :

$$H^*(k) = I \quad 4.66$$

Ce qui donne :

$$R^*(k)^{-1} = P(k \setminus k)^{-1} - P(k \setminus k-1)^{-1} \quad 4.67$$

Le gain du filtre avec la mesure équivalente est donné par :

$$\begin{aligned} K^*(k) &= P(k|k)H^*(k)'R^*(k)^{-1} \\ &= P(k|k)R^*(k)^{-1} \end{aligned} \quad 4.68$$

La mise à jour avec la mesure équivalente doit être rendre  $\hat{x}(k|k)$ , c'est-à-dire,

$$\begin{aligned} \hat{x}^*(k|k) &= \hat{x}(k \setminus k-1) + K^*(k)[z^*(k) - \hat{x}(k \setminus k-1)] \\ &= \hat{x}(k|k) \end{aligned} \quad 4.69$$

Où l'équation (4.66) a été utilisée. Ainsi, la mesure équivalente est donnée par :

$$z^*(k) = \hat{x}(k \setminus k-1) + K^*(k)^{-1}[\hat{x}(k|k) - \hat{x}(k \setminus k-1)] \quad 4.70$$

Et l'innovation équivalente à l'instant  $k$  est donnée par :

$$v^*(k) = K^*(k)^{-1}[\hat{x}(k|k) - \hat{x}(k \setminus k-1)] \quad 4.71$$

Sachant que  $K^*(k)$  défini dans (4.68) est inversible. La covariance de l'innovation équivalente à l'instant  $k$  est donnée par :

$$S^*(k) = P(k \setminus k-1) + R^*(k) \quad 4.72$$

où :

$$S^*(k)^{-1} = P(k \setminus k-1)^{-1} - P(k \setminus k-1)^{-1}P(k \setminus k)P(k \setminus k-1)^{-1} \quad 4.73$$

Cela complète la définition de la mesure  $z^*(k)$ , c'est équivalent aux mesures séquentielle  $\{z(k-1+1, \dots, z(k))\}$ . Au suivant le seul terme nécessaire est (4.73).

### 4.5.3 L'algorithme sous optimal BL1

En utilisant l'idée des mesures équivalentes, on peut exécuter dans une étape la mise à jour de  $l$  pas de retard OOSM selon l'algorithme sous-optimal BL1 [7].

Le filtrage par l'algorithme BL1 possède deux phases (figure 4-9) :

- Une phase de rétrodiction qui évalue le vecteur d'état  $x$  de  $k$  à  $\kappa$ .
- Une phase de correction qui corrige le vecteur d'état en utilisant les observations (les mesures OOSM)  $z(\kappa)$ .

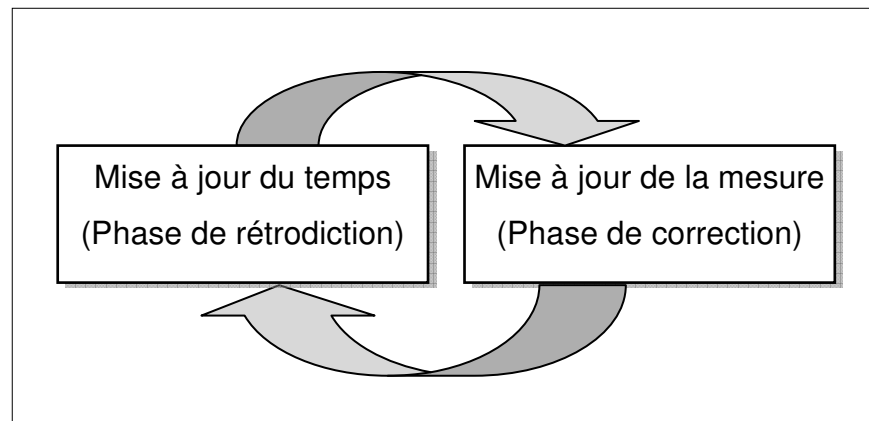


Figure 4.9 : Le cycle de l'algorithme BL1

### ■ La Rétrodition

La rétrodition d'état de l'instant  $k$  à l'instant  $\kappa$  est donnée par :

$$\hat{x}^B(\kappa|k) = F(\kappa, k) \hat{x}(k|k) \quad 4.74$$

Contrairement de (4.40), une fonction linéaire de  $\hat{x}(k|k)$ .

Les covariances associées à la rétrodition d'état sont calculées comme :

$$P_{vv}^B(k, \kappa) = Q(k, \kappa) \quad 4.75$$

$$P_{xv}^B(k, \kappa) = Q(k, \kappa) - P(k|k-l) S^*(k)^{-1} Q(k, \kappa) \quad 4.76$$

La rétrodition de la covariance d'état est donnée par :

$$P^B(\kappa|k) = F(\kappa, k) \left[ P(k|k) + P_{vv}^B(k, \kappa|k) - P_{xv}^B(k, \kappa|k) - P_{xv}^B(k, \kappa|k)' \right] F(\kappa, k)' \quad 4.77$$

### ■ Mise à jour

La covariance de la rétrodition de la mesure est donnée par :

$$S^B(\kappa) = H(\kappa) P^B(\kappa|k) H(\kappa)' + R(\kappa) \quad 4.78$$

La covariance entre l'état à l'instant  $k$  et cette mesure est calculée par :

$$P_{xz}^B(k, \kappa|k) = \left[ P(k|k) - P_{xv}^B(k, \kappa|k) \right] F(\kappa, k)' H(\kappa)' \quad 4.79$$

Le gain utilisé pour la mise à jour est calculé par :

$$K^B(k, \kappa) = P_{xz}^B(k, \kappa|k) S^B(\kappa)^{-1} \quad 4.80$$

où la prédiction par l'OOSM est donnée par :



$$\hat{z}^B(\kappa|k) = H(\kappa)\hat{x}^B(\kappa|k) \quad 4.81$$

La mise à jour par la mesure OOSM  $z(\kappa)$  de l'estimation d'état la plus récente  $\hat{x}(k|k)$  est donné par :

$$\hat{x}^B(k|\kappa) = \hat{x}(k|k) + K^B(k, \kappa) [z(\kappa) - \hat{z}^B(\kappa|k)] \quad 4.82$$

Le calcul de covariance pour la mise à jour de l'estimation d'état est donné par :

$$P^B(k|\kappa) = P(k|k) - P_{xz}^B(k, \kappa|k) S^B(\kappa)^{-1} P_{xz}^B(k, \kappa|k)' \quad 4.83$$

#### 4.6 L'Algorithme IMM-OOSM pour cible manœuvrante

L'état de l'art de poursuite des cibles réelles (manœuvrante) est l'estimateur à modèle multiple interagissant (IMM). Récemment, l'OOSM examine le problème dans un cadre général de Bayes. Pour intégrer l'OOSM dans l'estimateur IMM par l'approche BI1 [6,7], l'algorithme est présenté ci-dessous.

L'approche utilise la rétrodiction d'état dans l'estimateur IMM d'une manière découplée pour chaque modèle, en utilisant les méthodes de [6] et [7]. La fonction de vraisemblance de chaque modèle à l'instant de l'OOSM est évaluée et utilisée dans l'IMM. Les états d'estimations et leurs covariances des nouveaux modèle-conditionné courants sont calculées en utilisant l'OOSM et les probabilités de modèles sont également mises à jour avec l'OOSM. Enfin, les nouveaux états d'estimations combinés et les covariances sont obtenus [8].

L'intégration de l'OOSM dans l'estimateur IMM est illustrée par la figure (4-10).

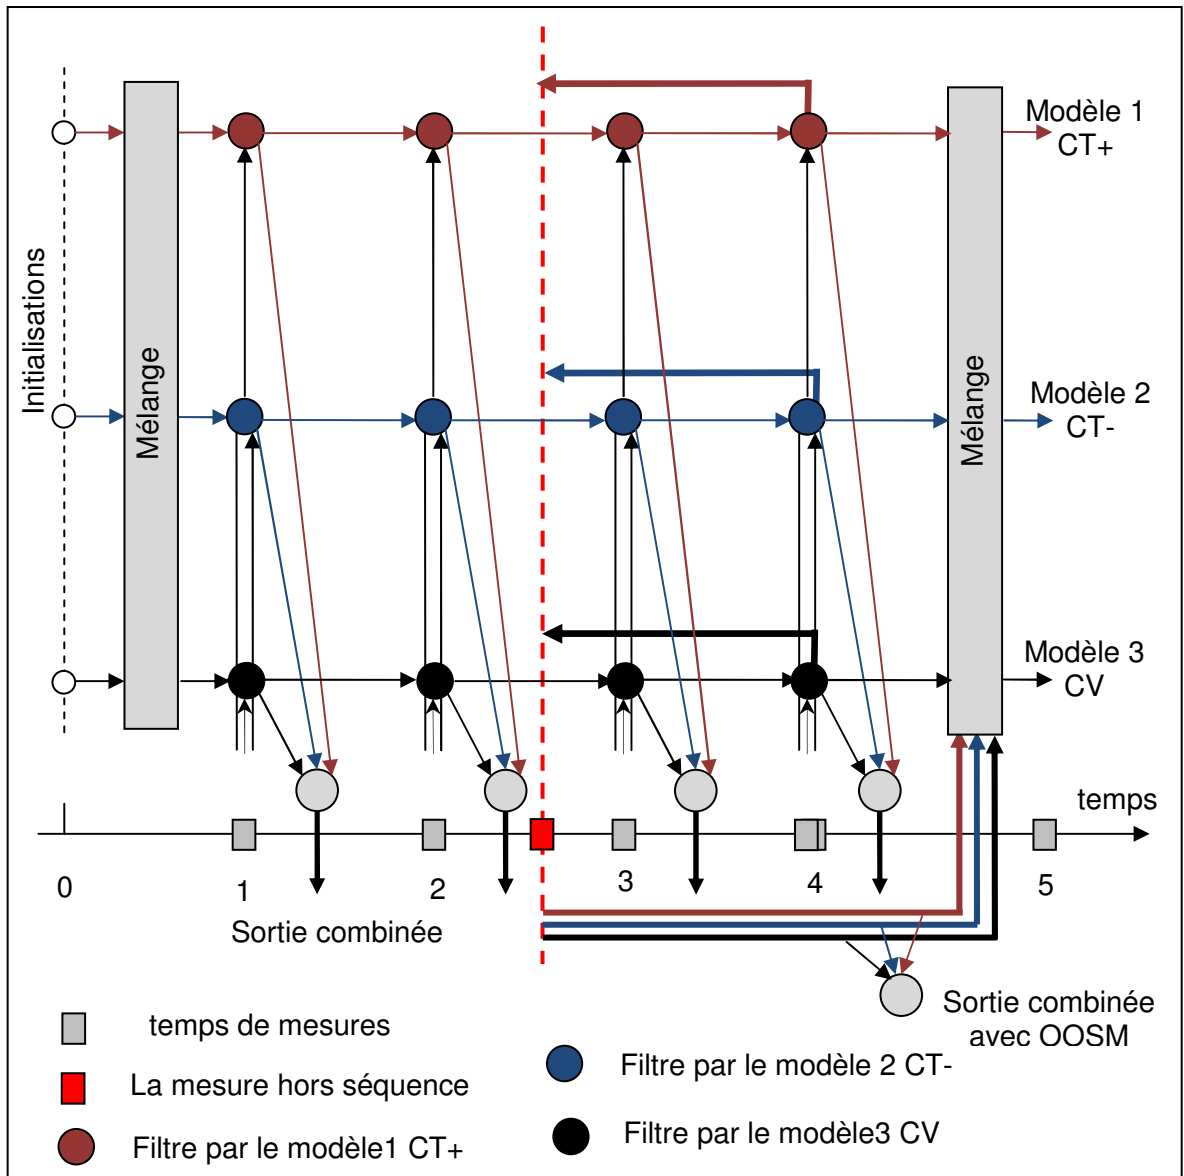


Figure 4.10 : l'intégration de l'OOSM dans l'IMM

### ■ Rétrodiction

#### – Rétrodiction d'état

Dans chaque modèle  $i$  ( $i=1,\dots,r$ ) de l'IMM, on effectue la rétrodiction (prédiction vers l'arrière) de  $k$  à  $\kappa$  [8].

soit  $t_{k-1} < \tau = t_{\kappa} < t_{k-1+1}$

où  $t_{\kappa}$  est le temps d'arrivé de la mesure OOSM,  $t_k$  est le temps des mesures courantes.

La rétrodiction de l'état  $x^i$  d'un modèle  $i$  de  $k$  à  $\kappa$  est donnée par :

$$\hat{x}^i(\kappa|k) = F^i(\kappa, k) \hat{x}^i(k|k)$$

4.84

où  $F^i(\kappa, k)$  est la matrice de transition vers l'arrière du modèle  $i$  de  $k$  à  $\kappa$ .

Les covariances associées à la rétrodiction de l'état sont calculées comme suit :

La covariance de l'effet cumulatif des processus de bruit de modèle  $i$  de  $k$  à  $\kappa$  est donnée par :

$$P_{vv}^i(k, \kappa) = Q^i(k, \kappa) \quad 4.85$$

La covariance de croisement (cross-covariance) du modèle  $i$  entre l'état  $x$  à l'instant  $k$  et le processus de bruit à l'instant  $k$  vers  $\kappa$  est donnée par :

$$P_{xv}^i(k, \kappa) = Q^i(k, \kappa) - P^i(k | k-1) S^{*i}(k)^{-1} Q^i(k, \kappa) \quad 4.86$$

où

$$S^{*i}(k)^{-1} = P^i(k | k-1)^{-1} - P^i(k | k-1)^{-1} P^i(k | k) P^i(k | k-1)^{-1} \quad 4.87$$

Cette équation (4.87) est la clé de l'algorithme BI1 qui réduit le problème de  $l$  pas de retard à 1-pas de retard.

La covariance (calculé par le filtre) de l'état de rétrodiction est donnée par :

$$P^i(\kappa | k) = F^i(\kappa, k) \left[ P^i(k | k) + P_{vv}^i(k, \kappa | k) - P_{xv}^i(k, \kappa | k) - P_{xv}^i(k, \kappa | k)' \right] F^i(\kappa, k)' \quad 4.88$$

– Rétrodition de mesures

La rétrodition de mesure  $\hat{z}^i(\kappa | k)$  de modèle  $i$  est calculé pour chaque  $r$  modèle de l'estimateur IMM.

La rétrodition des mesures OOSM d'un modèle  $i$  est donnée par :

$$\hat{z}^i(\kappa | k) = H(\kappa) \hat{x}^i(\kappa | k) \quad 4.87$$

La covariance de l'innovation  $S^i(\kappa | k)$  de l'OOSM de modèle  $i$  est donné par :

$$S^i(\kappa) = H(\kappa) P^i(\kappa | k) H(\kappa)' + R(\kappa) \quad 4.88$$

■ Mise à jour

– mise à jour de l'état et la covariance

La mise à jour de l'état au temps courant  $t_k$  de chaque modèle de l'IMM utilisant l'OOSM est faite comme ci-dessous [8].

La covariance entre l'état à l'instant  $k$  et cette mesure est :

$$P_{xz}^i(k, \kappa | k) = \left[ P^i(k | k) - P_{xv}^i(k, \kappa | k) \right] F^i(\kappa, k)' H(\kappa)' \quad 4.89$$

Le gain de filtre utilisé pour la mise à jour est donnée par :

$$K^i(k, \kappa) = P_{xz}^i(k, \kappa | k) S^i(\kappa)^{-1} \quad 4.90$$

La mise à jour de l'état d'estimation la plus récente  $\hat{x}(k/k)$  avec la mesure OOSM  $z(\kappa)$  est donnée par :

$$\begin{aligned} \hat{x}^i(k | Z^\kappa, z(\kappa)) &= \hat{x}^i(k | Z^\kappa) + K^i(k, \kappa) [z(\kappa) - \hat{z}^i(\kappa | k)] \\ \hat{x}^i(k | \kappa) &= \hat{x}^i(k | k) + K^i(k, \kappa) [z(\kappa) - \hat{z}^i(\kappa | k)] \end{aligned} \quad 4.91$$

La covariance de la mise à jour de l'estimation d'état est donné par :

$$P^i(k | \kappa) = P^i(k | k) - P_{xz}^i(k, \kappa | k) S^i(\kappa)^{-1} P_{xz}^i(k, \kappa | k)' \quad 4.92$$

– Mise à jour des probabilités des modèles

La fonction de vraisemblance de chaque modèle  $i$  à l'instant  $\kappa$  est évaluée et en basant sur les mesures OOSM et la rétrodiction du temps courant.

$$\Lambda_i(\kappa) = \left| 2\pi S^i(\kappa | k) \right|^{-1/2} \exp \left\{ -\frac{1}{2} [z(\kappa) - \hat{z}^i(\kappa | k)]' S^i(\kappa | k)^{-1} [z(\kappa) - \hat{z}^i(\kappa | k)] \right\} \quad 4.93$$

Le vecteur résultant se compose de toutes les fonctions de vraisemblance des modèles  $i = 1, \dots, r$  dans l'estimateur IMM à l'instant  $\kappa$  :

$$\Lambda(\kappa) = [\Lambda_1(\kappa), \dots, \Lambda_r(\kappa)]' \quad 4.94$$

La mise à jour des probabilités de modèle au temps courant est faite comme suit :

Les probabilités de modèle au temps  $k$  (avant l'OOSM), donné par le vecteur

$$\mu(k | k) = [\mu_1(k | k), \dots, \mu_r(k | k)]' \quad 4.95$$

Doit être mis à jour avec l'OOSM en :

$$\mu(k | \kappa) = [\mu_1(k | \kappa), \dots, \mu_r(k | \kappa)]' \quad 4.96$$

Selon

$$\mu_i(k | \kappa) = \frac{1}{c} \sum_{j=1}^r \Lambda_j(\kappa) \mu_j(k | k) \quad 4.97$$

où la constante de normalisation donnée par

$$c = \sum_{j=1}^r \Lambda_j(\kappa) \mu_j(k | k) \quad 4.98$$

Il est important de dire que ces résultats sont limités dans certains cas.

Les deux cas limités sont :

➤ Un OOSM très ancien "vieil", c'est-à-dire :

$$T = t_k - \tau = t_k - t_\kappa \rightarrow \infty$$

Dans ce cas-ci la mise à jour de probabilité de modèle devient :

$$\mu_i(k | \kappa) = \mu_i(k | k) \quad 4.99$$

Ainsi, un ancien OOSM n'a aucune influence sur les probabilités de modèle courant.

➤ Un OOSM très récent (très petit), c'est-à-dire

$$T = t_k - \tau = t_k - t_\kappa \rightarrow 0.$$

Dans ce cas-ci (c'est notre cas) la mise à jour de probabilités de modèle devient :

$$\mu_i(k | \kappa) = \frac{1}{c} \sum_{j=1}^r \Lambda_j(\kappa) \mu_j(k | k) \quad 4.100$$

– Combinaison des états estimés et covariances

Les nouvelles estimations globales de l'état et de la covariance après l'OOSM sont :

$$\begin{cases} \hat{x}(k | \kappa) = \sum_{j=1}^r \hat{x}^j(k | \kappa) \mu_j(k | \kappa) \\ P(k | \kappa) = \sum_{j=1}^r \mu_j(k | \kappa) \left\{ P^j(k | \kappa) + [\hat{x}^j(k | \kappa) - \hat{x}(k/\kappa)] \times [\hat{x}^j(k/\kappa) - \hat{x}(k | \kappa)]' \right\} \end{cases}$$

4.101

#### 4.7 Conclusion

Nous avons présenté dans ce chapitre quelques algorithmes utilisés pour résoudre le problème des mesures hors séquence (optimal, sous optimal) dans le cas d'une cible non manœuvrante. Ensuite avons décrit l'application de l'algorithme OOSM (BI1) à l'algorithme d'estimateur modèle multiple interagissant (IMM) au cas d'une cible manœuvrante.

## **CHAPITRE 5**

### **SIMULATION ET COMMENTAIRES**

#### 5.1 Introduction

Dans ce dernier chapitre, nous allons décrire les différents modèles de trajectoires qui vont servir à tester l'algorithme OOSM (BL1) puis l'algorithme IMM-OOSM (IMM-BL1). Nous ferons ensuite une analyse détaillée des résultats que nous avons obtenus lors des simulations que nous avons effectuées.

#### 5.2 L'objet de la simulation

La simulation telle qu'elle est définie généralement est un outil de prédiction permettant d'étudier et d'analyser le comportement des systèmes complexes afin de prendre des décisions de façon plus objective et scientifique.

En simulation, le système est modélisé par un ensemble de structures de données interconnectées et un ensemble de procédures qui opèrent sur ces structures définissant ainsi la dynamique du système.

L'évolution des performances du système est prise d'après son quantitatif c'est-à-dire, lié à démontrer les propriétés du comportement du système, ainsi que sa compréhension à partir de son aspect fonctionnel.

#### 5.3 Simulation de l'algorithme OOSM (BL1)

Pour tester le bon fonctionnement de l'algorithme OOSM (BL1) dans cette partie, nous avons généré une trajectoire de forme rectiligne.

##### 5.3.1 Génération de trajectoire rectiligne

Dans ce cas, nous avons généré une trajectoire rectiligne à deux dimensions à vitesse constante. Cette trajectoire sera modélisée par un modèle d'état discret de type CV :

Cette trajectoire rectiligne de direction  $\theta$  quelconque est constituée d'un tronçon de droite à vitesse  $v$  constante (modèle CV). Pour la générer, nous avons projeté l'équation  $d = vt$  sur les axes  $x$  et  $y$  du repère :

$$x = vt \cos(\theta) \quad \text{et} \quad y = vt \sin(\theta)$$

Ceci est illustré dans la figure 5.1.




Figure 5.1 : Génération de la trajectoire rectiligne

### 5.3.2 L'organigramme général de l'algorithme BL1 (OOSM)

L'algorithme BL1 pour la simulation de la poursuite des cibles (non manœuvrantes) multi-capteurs par un traqueur central est représenté dans la figure 5.2. Il se compose d'une partie initialisation, d'un filtre de Kalman (avant les mesures hors séquence) et d'un filtre BL1 dans le cas de la présence d'une mesure hors séquence :

Les étapes de l'algorithme BL1 sont organisées de la manière suivante :

- initialisation du filtre de Kalman,
- Test sur la présence ou non d'une mesure hors séquence.
  - Si absence, on suit l'algorithme KF :
    - Prédiction de l'état et la covariance du modèle CV,
    - Calcul du gain, de l'innovation de mesure et de covariance,
    - Correction de l'état et la covariance du modèle,

- Calcul de l'état final et la covariance finale.
- Si présence, on suit l'algorithme BL1 :
  - Rétrodition de l'état et la covariance du modèle CV,
  - Calcul du gain, de l'innovation de mesure et de covariance,
  - Correction de l'état et la covariance du modèle,
  - Calcul de l'état final et la covariance finale.

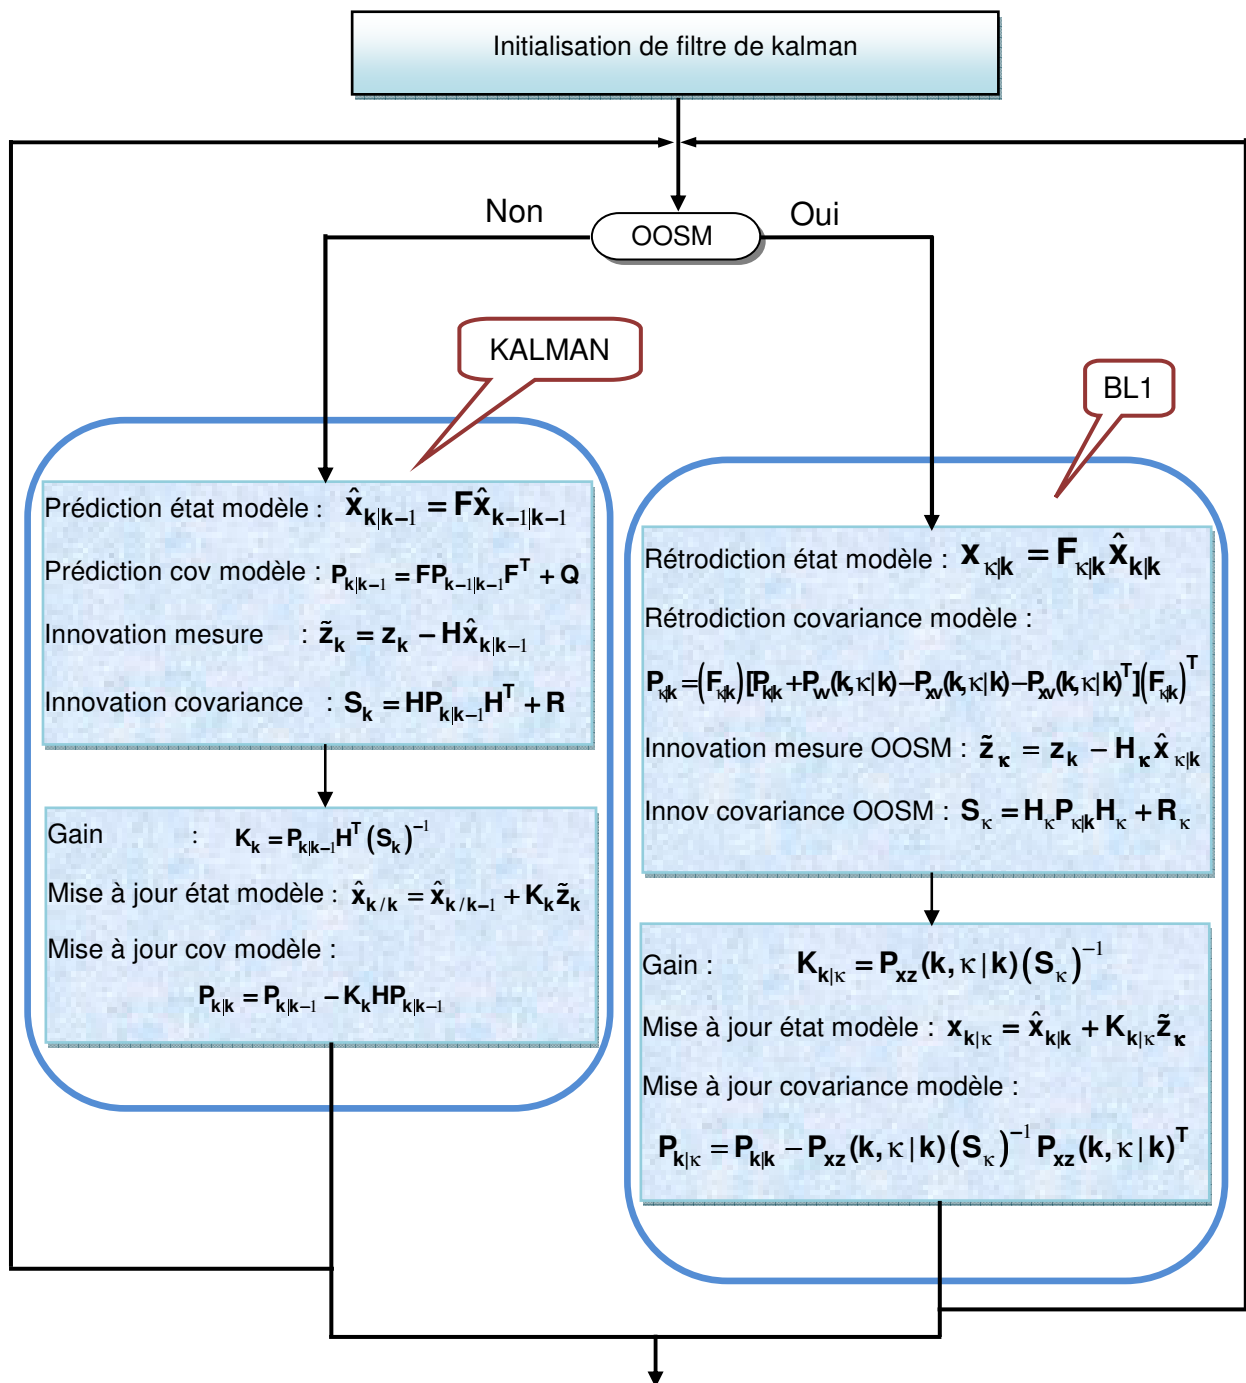


Figure 5.2 : Organigramme de l'algorithme OOSM (BL1)



### 5.3.3 Résultats de simulation OOSM (BL1) la trajectoire rectiligne

Dans cette partie, nous simulons la poursuite d'une cible multi-capteur (deux capteurs) centralisée se déplaçant selon une trajectoire rectiligne à vitesse constante. Nous utilisons donc un modèle CV de différents cas (capteurs 1 seul, capteurs en séquence et traitement OOSM).

Nous présentons quelques résultats avec différents scénarios.

#### ■ Scénario 1

Dans ce scénario, La cible se déplace le long d'une trajectoire rectiligne à une vitesse constante  $v=10\text{m/s}$  dans une direction  $\theta=$  de  $45^\circ$  pendant 100 secondes, et un retard  $L=1$  puis  $L=2$  de la mesure du capteur 2 par rapport au capteur 1.

L'erreur de position est calculée selon la formule suivante :

$$e(t) = \sqrt{(x(t) - \hat{x}(t))^2 + (y(t) - \hat{y}(t))^2}$$

Où  $x$  et  $y$  sont les coordonnées à l'instant  $t$  de la trajectoire réelle, et  $\hat{x}$  et  $\hat{y}$ , les coordonnées à l'instant  $t$  de la trajectoire estimée selon l'un des modèles.

– Pour  $L=1$  :




Figure 5.3 : Poursuite de la trajectoire selon KF (capteur 1, en séquence) et OOSM (BL1) (scénario 1) ( $L=1$ )




Figure 5.4 : Erreurs de position selon KF (capteur 1, en séquence) et l'OOSM (BL1) (scénario 1) (L=1)

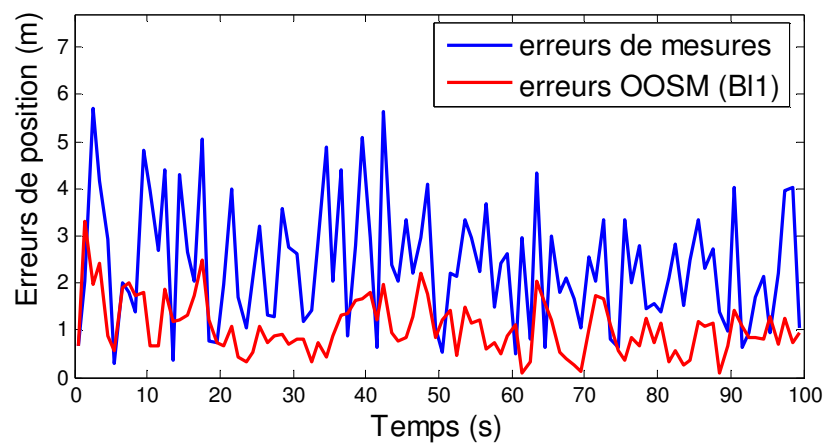


Figure 5.5 : Erreurs de position selon l'OOSM (BL1) et les positions mesurées (scénario 1) (L=1)

– Pour L=2 :




Figure 5.6 : Poursuite de la trajectoire selon KF (capteur 1, en séquence) et OOSM (BL1) (scénario 1) (L=2)




Figure 5.7 : Erreurs de position selon KF (capteur 1, en séquence) et l'OOSM (BL1) (scénario 1) (L=2)




Figure 5.8 : Erreurs de position selon l'OOSM (BL1) et les positions mesurées (scénario 1) (L=2)

#### 5.3.4 Interprétation des résultats

L'algorithme BL1 (OOSM) appliqué au cible non manœuvrante que nous avons mis en œuvre a montré son efficacité au cas de poursuite de cible multi-capteurs centralisé avec de petits retard ( $L=1, 2, 3$ ). L'application de cet algorithme au premier scénario a donné des très bon résultats qui sont présentés dans les figures (5.3, 5.6). Ces figures montrent que la trajectoire estimée représentée en vert est identique à celle de trajectoire où toute les mesures arrivent en séquence (représentée en rouge).

Cette simulation est confirmée par les faibles erreurs de position montré dans les figures 5.(4,5,7,8),et nous remarquons que les erreurs de l'OOSM (BI1) (en vert) est identique au cas où les deux capteurs sont aligné (en séquence).

Le tableau 5.1 montre les moyennes des erreurs de position effectuées sur 50 simulations aléatoires. Ce tableau est constitué de trois colonnes avec les trois cas étudié (capteur1, en séquence, OOSM (BI1)) selon trois lignes des différents pas de retard (L=1, 2,3).

Retard (Lag) L	Radar 1 (avant traitement OOSM) KF	En séquence (l'optimal) KF	OOSM (traitement OOSM) BI1
1	1.3646	1.1083	1.1714
2	1.4647	1.1944	1.2621
3	1.5734	1.2833	1.3551

Tableau 5.1 : La moyenne des erreurs de position (radar 1, en séquence et OOSM (scénario) (L=1)

Les résultats de ce tableau ont étaient obtenus en changeant à chaque fois le pas de retard. On constate finalement que la moyenne des erreurs de position de cas où toute les mesures arrivent en séquence est meilleur (plus petit), la moyenne des erreurs OOSM (BL1) est petite par rapport aux cas de radar1 seul, et plus proche au cas où les deux capteurs sont alignés, ce qui confirme l'efficacité de l'algorithme BL1.

Ainsi, la moyenne des erreurs quadratique est augmentée quand le retard est plus grand.

La partie précédente traite le problème des mesures hors séquence par l'algorithme OOSM (BI1) ce dernier est limité au cas de la poursuite de cibles non manœuvrantes. Pour traiter le problème de retard de mesure (MHS) au cas de la poursuite de cibles manœuvrantes on applique l'algorithme à modèle multiples interagissant (IMM) basé sur l'algorithme OOSM (BI1). Ceci est illustré dans la partie suivante.

### 5.4 Simulation de l'algorithme IMM-OOSM (IMM-BL1)

Dans la deuxième partie de notre travail, nous avons générée une trajectoire constituée d'un tronçon de forme rectiligne suivi d'un arc de cercle.

#### 5.4.1 Génération de la trajectoire à virage

Cette trajectoire est constituée d'un tronçon rectiligne de direction  $\theta$  quelconque parcourue à vitesse  $v$  constante (modèle CV), suivi d'un virage à gauche ou à droite, de rayon de courbure  $R$ , de taux de virage  $\omega$  constant et d'angle  $\varphi$  (modèle CT).

Pour la générer, nous avons procédé en deux étapes :

➤ Génération d'une trajectoire horizontale constituée des deux tronçons D1 de durée  $t_1$  et D2 de durée  $t_2$  en écrivant :

- pour le premier tronçon  $x = vt$
- pour le second tronçon  $x = R \cos \omega t$  et  $y = R \sin \omega t$

➤ Rotation de la trajectoire résultante d'un angle  $\theta$

Ceci est illustré dans la figure 5.3.

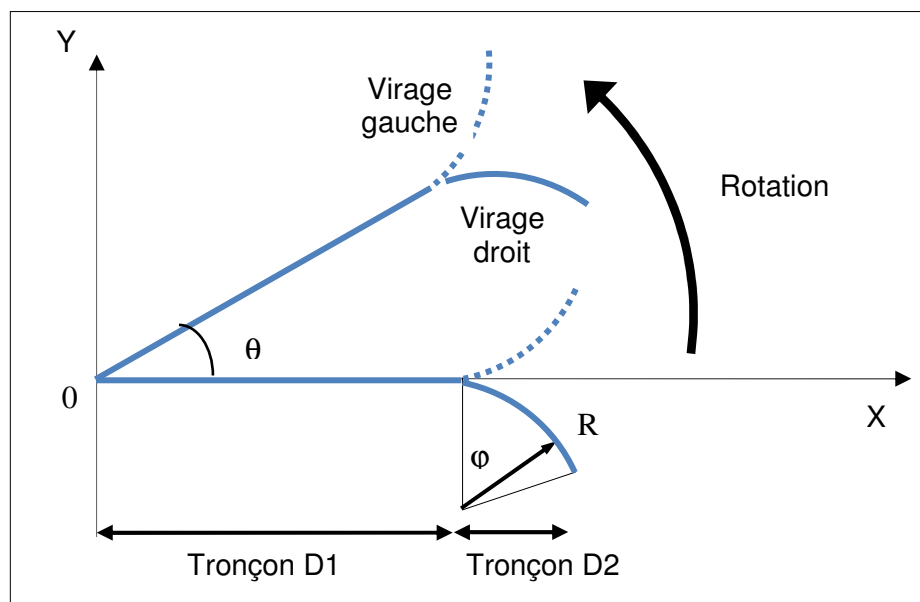


Figure 5.9 : Génération de la trajectoire à deux tronçons

### 5.4.2 Organigramme général de l'algorithme IMM-OOSM

L'algorithme IMM-OOSM pour la simulation de la poursuite des cibles manœuvrantes multi-capteurs par un traqueur central est représenté dans l'organigramme de la figure 5.10. Il se compose d'une partie initialisation, de trois filtres de Kalman en parallèles dans la partie de l'IMM (sans mesure hors séquence) et de deux ou trois filtres BL1 dans le cas de traitement OOSM (IMM-OOSM) :

Un modèle CV, un modèle CT gauche (vitesse  $\omega$  négative) et un modèle CT droit (vitesse  $\omega$  positive). Chaque modèle de l'algorithme IMM-OOSM suit les étapes de l'organigramme ci-dessous :

➤ Il débute par l'initialisation de la probabilité de transition  $p_{ij}$ , La probabilité d'utilisation  $\mu_0^j$ , la covariance de l'erreur  $P_0^j$  et l'état initial du vecteur d'état  $x_0^j$

➤ Test de présence ou d'absence d'une mesure hors séquence :

■ Si absence, on suit l'algorithme IMM :

- Calcul de la probabilités d'utilisation  $\mu_{ij}$ ,
- Calcul de l'état et la covariance initial mélangés,
- Prédiction de l'état et la covariance du modèle  $j$ ,
- Calcul du gain, de l'innovation de mesure et de covariance et la fonction de vraisemblance,
- Correction de l'état et la covariance du modèle  $j$ ,
- Calcul de l'état final et la covariance finale.

■ Si présence, on suit l'algorithme IMM-OOSM :

- Rétrodiction de l'état et la covariance du modèle  $j$ ,
- Calcul du gain, de l'innovation de mesure et de covariance et la fonction de vraisemblance,
- Correction de l'état et la covariance du modèle  $j$ ,
- Calcul de l'état final et la covariance finale.

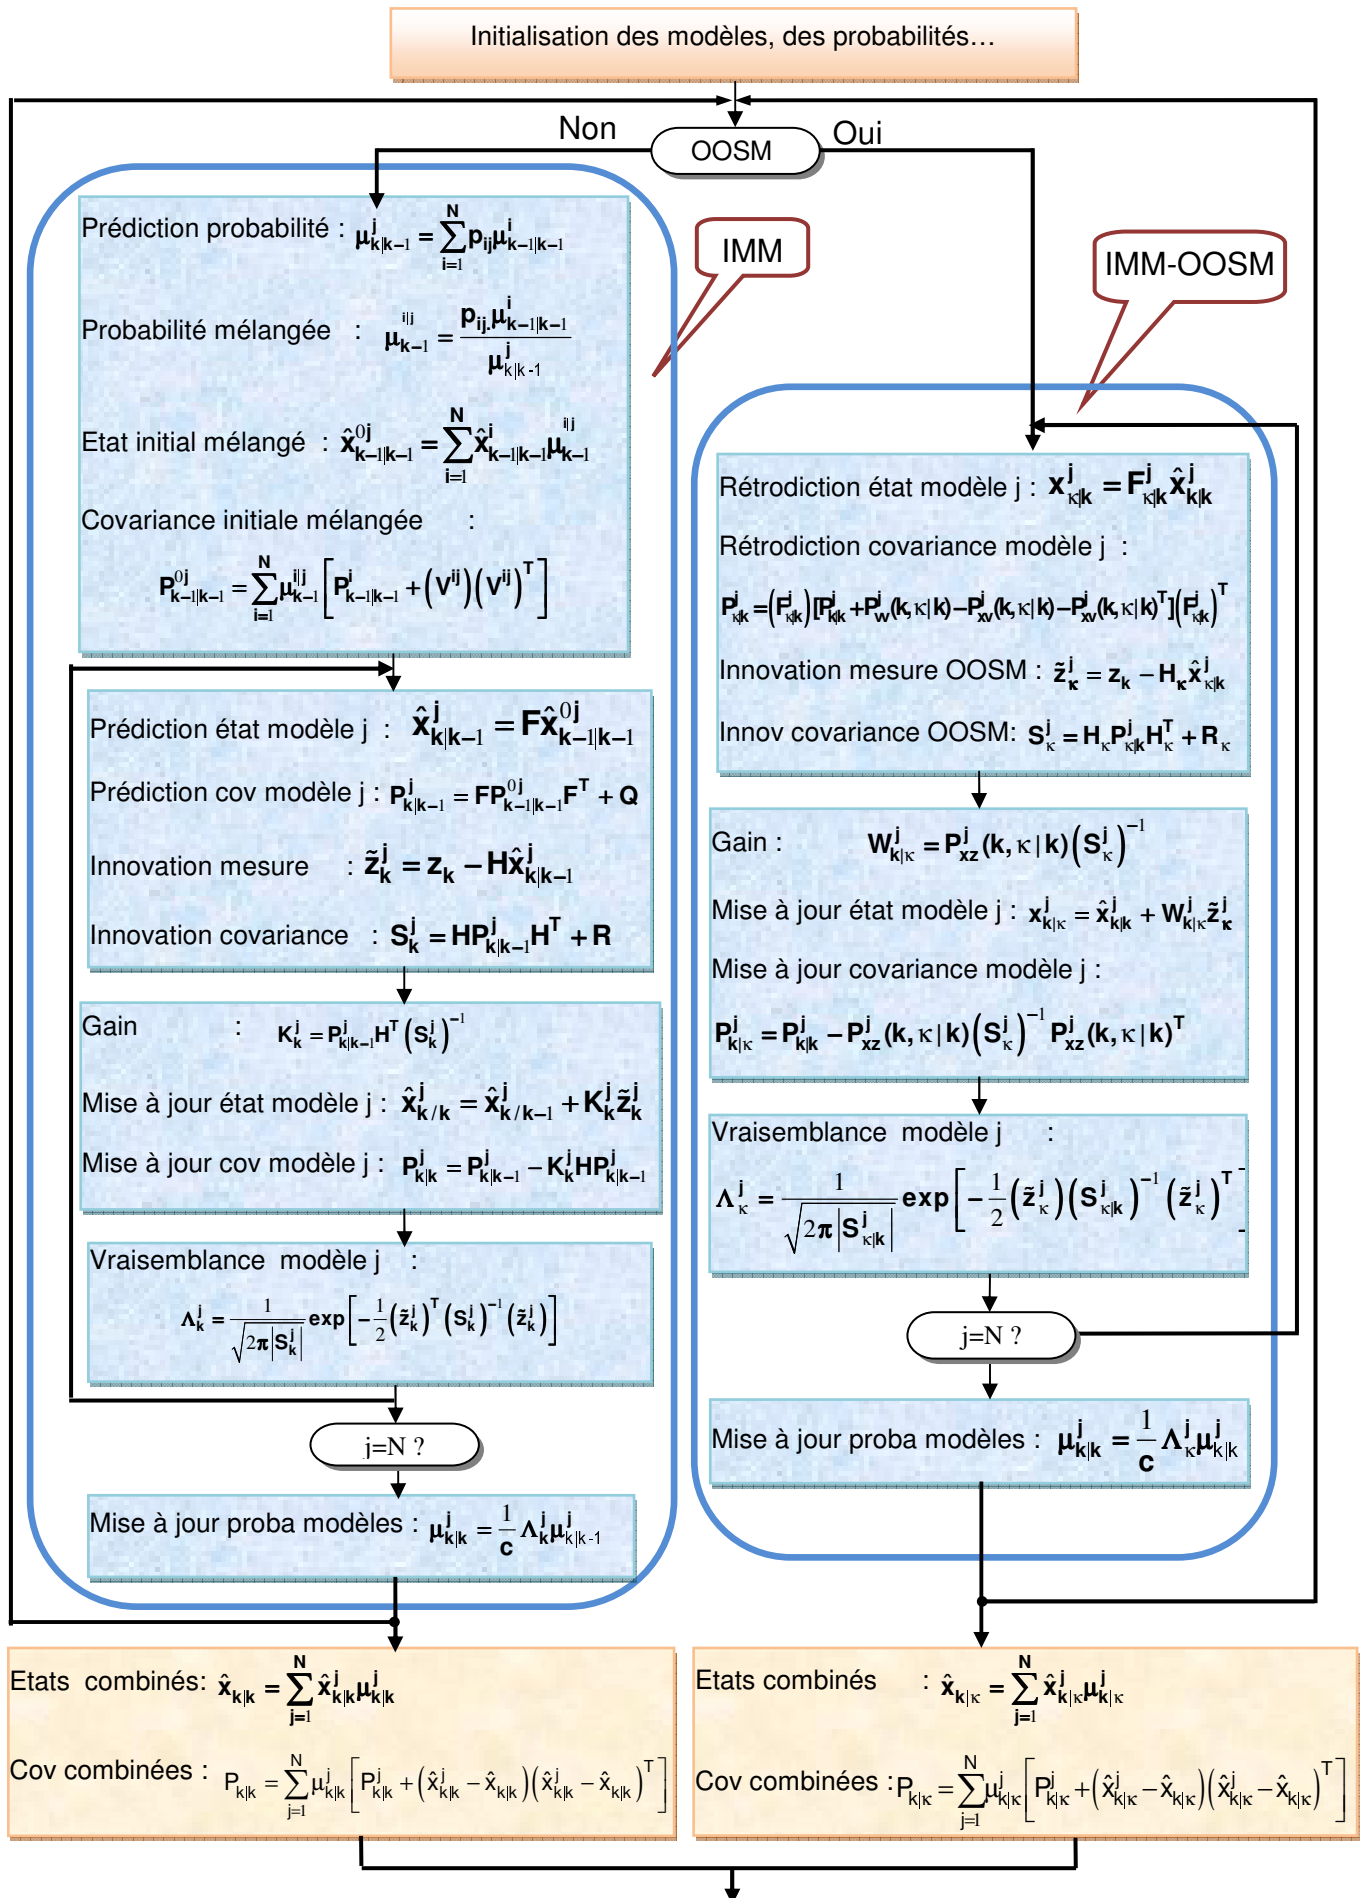


Figure 5.10: Organigramme de l'algorithme IMM-OOSM

### 5.4.3 Présentation générale de l'interface (IMM-OOSM)

Cette interface est utilisée pour simuler la trajectoire comprenant un tronçon à vitesse constante suivie d'un virage à gauche ou à droite. L'interface que nous proposons comprend six zones distinctes (figure 5.11) :

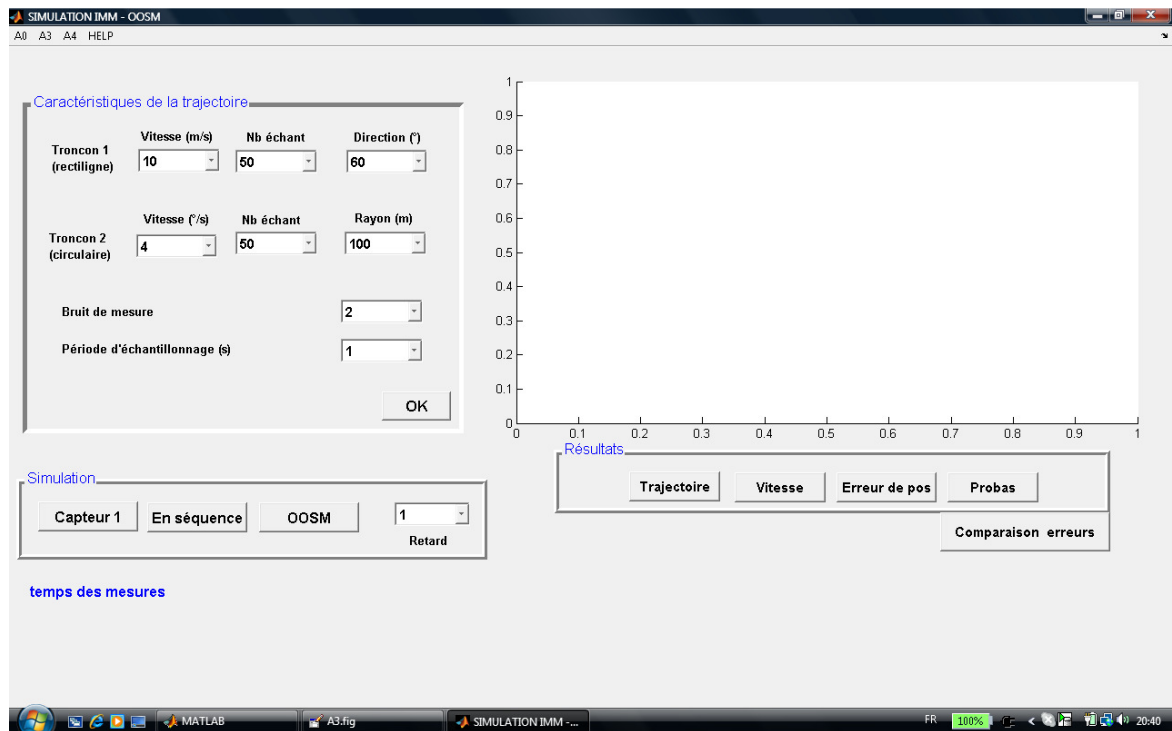


Figure 5.11 : L'interface

Elle comprend six zones distinctes :

■ 1<sup>ère</sup> zone

Elle est située en haut et à gauche de la fenêtre. C'est la zone réservée à la lecture des données relatives à la trajectoire à simuler. Dans cette zone nous donnons tous les paramètres utiles pour simuler les algorithmes IMM et IMM avec traitement OOSM (IMM-OOSM).

Ces paramètres sont les suivants :

- Les paramètres du tronçon D1 à vitesse constante
  - vitesse  $v$
  - durée du tronçon
  - direction  $\theta$  de la trajectoire;



- Les paramètres du tronçon D2 à virage
  - vitesse angulaire  $\omega$
  - durée du tronçon
  - rayon de courbure R
- La période d'échantillonnage
- Le bruit de mesure
- Un bouton poussoir (OK) : pour déclencher la simulation

#### ■ 2<sup>ème</sup> zone

Dans cette zone (au centre et à gauche de la fenêtre), l'utilisateur indique les différents cas de simulation (le capteur1 seul, les deux capteurs en séquence, OOSM) et le retard de mesure.

#### ■ 3<sup>ème</sup> zone

Dans cette zone (en bas, à gauche), nous avons une zone de texte pour afficher le temps d'arrivés des mesures.

#### ■ 4<sup>ème</sup> zone

Dans cette zone (en bas, à droite), nous avons quatre « pushboutton » permettent à l'utilisateur le tracé de différentes graphes (trajectoire, vitesse, erreur de position et probabilité de l'IMM) en fonction du type de simulation (capteur1, en séquence, OOSM), plus un autre « pushboutton » pour l'affichage de comparaison des erreurs des différents cas de simulation.

#### ■ 5<sup>ème</sup> zone

Cette zone (en haut à droite) est utilisée pour visualiser les graphes.

### 5.4.4 Résultats de simulations

Pour évaluer les performances de l'algorithme OOSM (BL1) et l'IMM avec une ou plusieurs mesures hors séquence (IMM-OOSM), nous avons élaboré différents scénarios nous permettant de tirer des conclusions.

Pour le cas des cibles manœuvrantes nous avons généré une trajectoire avec différents paramètres (vitesse, taux de virage...) et nous avons testé l'algorithme IMM, puis l'algorithme IMM-OOSM sur ces trajectoires et les différent cas :

- On tient compte des mesures d'un seul capteur (pas de mesures OOSM) : les mesures seront traitées par un filtre de Kalman classique.
- en séquence : on suppose que les mesures des deux capteurs sont dans l'ordre chronologique (c'est le cas idéal) : les mesures seront traitées par un filtre de Kalman classique.
- Les mesures de l'un des deux capteurs constituent des mesures hors séquence : elles seront traitées par l'algorithme OOSM (BL1).

Dans cette partie, nous simulons la poursuite multi-capteurs centralisée d'une cible manœuvrante se déplaçant selon une trajectoire constituée d'un tronçon rectiligne à vitesse  $v$  constante, suivi d'un virage avec un taux de virage  $\omega$  et de rayon de courbure  $R$ , Nous utilisons donc un modèle CV et des modèles CT gauche et CT droit, et les mesures de deuxième capteur reçus par le central traqueur est en retard par rapport au premier capteur. Nous présentons quelques résultats avec différents scénarios.

#### ■ Scénario 2

Dans ce scénario, la cible se déplace le long d'une trajectoire rectiligne à une vitesse constante  $v=10\text{m/s}$  dans une direction  $\theta$  de  $60^\circ$  pendant 50 secondes. A cet instant, la cible opère un virage à droite avec un taux de  $4\%/s$  pendant un angle de  $100^\circ$  et un retard de mesure  $L=1$  et  $L=2$ .

Nous avons utilisé les données suivantes :

- Le vecteur des probabilités initiales  $\mu(0) = [1 \ 0 \ 0]^T$

Ce qui signifie que nous considérons que la cible suit le premier modèle CV.

- Les probabilités de transition de la chaîne de Markov gouvernant le changement (switching) entre les trois modèles dans l'algorithme IMM à base de filtre de Kalman linéaire discret et l'algorithme IMM-OOSM à base de l'algorithme BL1 sont choisies comme suit pour tous les scénarios :

$$p_{ij} = \begin{bmatrix} 0.98 & 0.01 & 0.01 \\ 0.01 & 0.98 & 0.01 \\ 0.01 & 0.01 & 0.98 \end{bmatrix}$$

- La mesure  $z(k)$  de la position de cible est supposée acquise par un des deux radars,  $z(\kappa)$  c'est la mesure de position hors séquence (OOSM) de deuxième capteur. Comme ces mesures ne sont pas disponibles, nous les avons générées en ajoutant aux coordonnées  $x$  et  $y$  de la trajectoire réelle, un bruit blanc gaussien de variance  $\sigma_R^2$
- Le retard de mesure de capteur 2 par rapport au capteur 1 est choisis pour la première fois  $L=1$  puis  $L=2$ .
- Nous avons utilisé les modèles CV et CT vus dans le chapitre 2 pour représenter les tronçons de trajectoires et nous avons utilisé l'algorithme Bl1 vus dans le chapitre 4 pour le traitement OOSM.
- L'erreur de position est calculée selon la formule suivante :

$$e(t) = \sqrt{(x(t) - \hat{x}(t))^2 + (y(t) - \hat{y}(t))^2}$$

- La figure (5.13), nous montrons des résultats comparatifs de l'estimation de la vitesse selon l'IMM. La vitesse est calculée par la formule :

$$v(t) = \sqrt{\hat{x}(t)^2 + \hat{y}(t)^2}$$

Où  $\hat{x}$  et  $\hat{y}$  représentent les estimées des composantes de la vitesse de la cible.

Les figures suivantes montrent les résultats des simulations.

- Pour  $L=1$  :




Figure 5.12 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 2) ( $L=1$ )




Figure 5.13 : Estimation de la vitesse selon l'IMM seul (radar 1, en séquence) et l'IMM-OOSM (scénario 2) (L=1)




Figure 5.14 : Erreurs de position selon IMM seul (capteur 1, en séquence) et l'IMM-OOSM (scénario 2) (L=1)




Figure 5.15 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 2) (L=1)




Figure 5.16 : Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=1)




Figure 5.17 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=1)




Figure 5.18 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=1)

– Pour  $L=2$

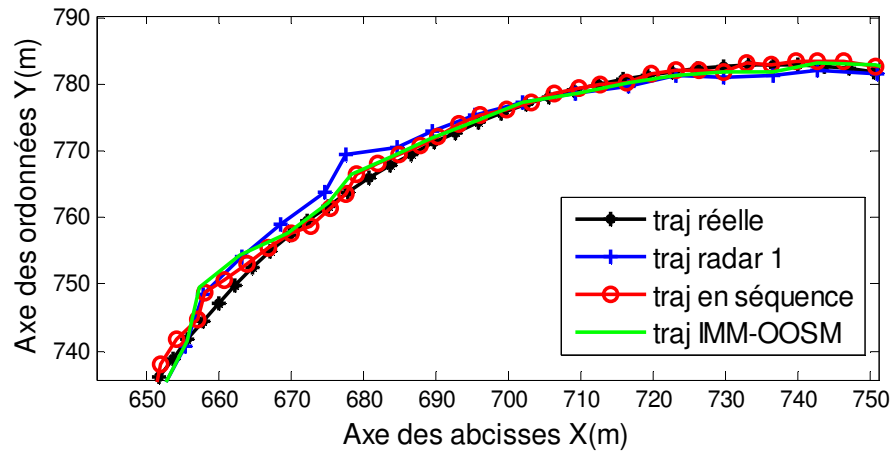


Figure 5.19 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 2) ( $L=2$ )




Figure 5.20 : Estimation de la vitesse selon l'IMM seul (radar 1, en séquence) et l'IMM-OOSM (scénario 2) ( $L=2$ )




Figure 5.21 : Erreurs de position selon IMM seul (capteur 1, en séquence) et l'IMM-OOSM (scénario 2) ( $L=2$ )




Figure 5.22 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 2) (L=2)




Figure 5.23 : Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=2)




Figure 5.24 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=2)




Figure 5.25 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 2) (L=2)

### ■ Scénario 3

Dans ce scénario, La cible se déplace le long d'une trajectoire rectiligne à une vitesse constante  $v=10\text{m/s}$  dans une direction  $\theta$  de  $60^\circ$  pendant 50 secondes. A cet instant, la cible opère un virage à gauche avec un taux de  $-3\%$  pendant un angle de  $80^\circ$  avec un retard de mesure  $L=1$  puis  $L=2$ .

Les figures suivantes montrent les résultats des simulations.

– Pour  $L=1$




Figure 5.26 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) (L=1)






Figure 5.27 : Estimation de la vitesse selon l'IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) (L=1)

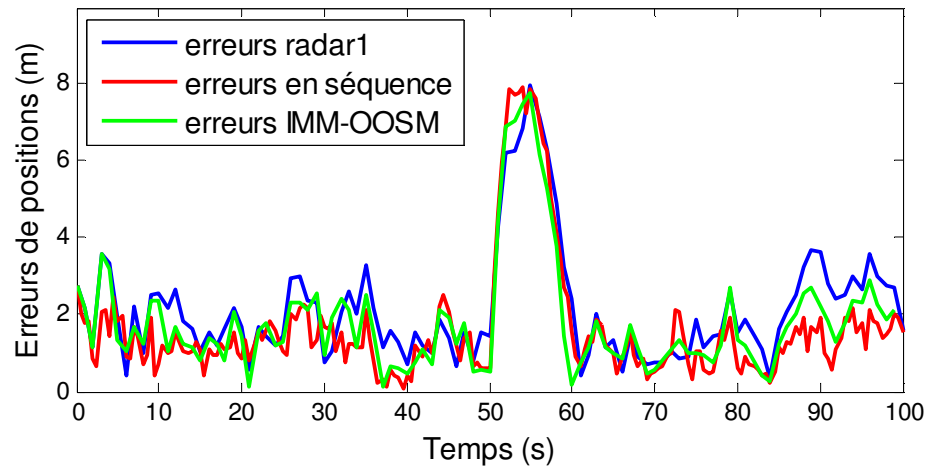


Figure 5.28 : Erreurs de position selon IMM seul (radar 1, en séquence) et IMM-OOSM (L=1)




Figure 5.29 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 3) (L=1)




Figure 5.30 : Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=1)




Figure 5.31 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=1)

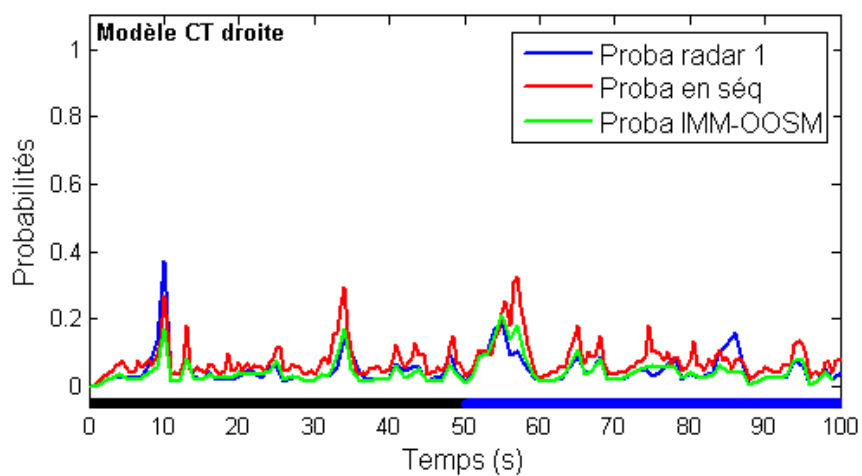


Figure 5.32 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=1)

– Pour  $L=2$




Figure 5.33 : Poursuite de la trajectoire selon IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) ( $L=2$ )




Figure 5.34 : Estimation de la vitesse selon l'IMM seul (radar1, en séquence) et l'IMM-OOSM (scénario 3) ( $L=2$ )




Figure 5.35 : Erreurs de position selon IMM seul (radar 1, en séquence) et IMM-OOSM (scénario 3) ( $L=2$ )

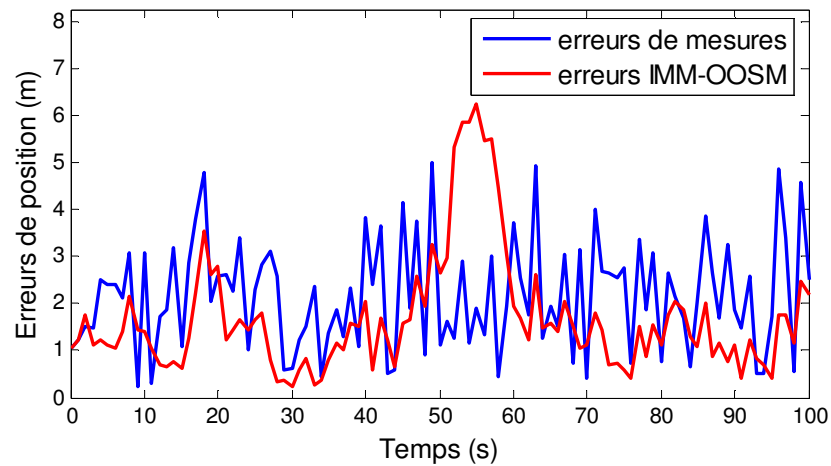


Figure 5.36 : Erreurs de position selon l'IMM-OOSM et les positions mesurées (scénario 3) (L=2)




Figure 5.37: Probabilités de modèles CV de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=2)




Figure 5.38 : Probabilités de modèles CT gauche de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=2)




Figure 5.39 : Probabilités de modèles CT droite de l'IMM seul (radar1, en séquence) et IMM-OOSM (scénario 3) (L=2)

#### 5.4.5 Interprétation des résultats

L'algorithme IMM-OOSM (IMM-BL1) appliqué au cibles manoeuvrantes que nous avons mis en œuvre a montré son efficacité au cas de la poursuite des cibles (manoeuvrante) multi-capteurs centralisées de petits retards (L=1, 2,3).

L'application de l'algorithme IMM-BL1 au deuxième scénario a donné des très bon résultats qui sont représenté dans les figures 5.(12,19,26,33). Ces figures montrent que cet algorithme s'adapte bien aux brusques changements de modèles de mouvements et que la trajectoires estimée par IMM-BL1 représentée en vert est plus proche (identique) à celle où le deux capteurs sont alignés(en rouge), et que l'estimation des différents mouvements des cibles a été effectuée par les bons filtres correspondants aux types de trajectoires. Pour s'en convaincre, il suffit d'examiner les courbes des probabilités illustrées par les figures 5.(16,17,18,30,31,32,37,38,39).

Cette similitude est confirmée par les faibles erreurs de position de l'IMM-BL1 (en vert) qui est identique au cas où les mesures arrivent en séquence(en rouge) contrairement au capteur1 seul (voir figures 5.(14,15,21,22,28,29,35,36).

Les figures 5.(16,23,30,37) et 5.(17,18,24,25,31,32,38,39)(probabilités des modèles CV et CT) montre que le filtre est destiné à traité le retard et estimé le mouvement rectiligne à vitesse constante (CV) a dominé l'estimation avant la détection du saut. Après qu'un saut est effectué, le filtre chargé d'estimer le

mouvement de virage domine l'estimation après 3 ou 4 échantillons qui suit ce saut.

Donc, nous pouvons dire que l'algorithme IMM à base de BL1 (IMM-BI1) traite le retard et il fait l'alignement des deux capteurs et converge rapidement.

Le tableau 5.2 montre les moyennes des erreurs de position effectuées sur 50 simulations aléatoires. Ce tableau est constitué de trois colonnes avec les trois cas étudié (capteur1, en séquence, OOSM (BI1)) selon trois lignes des différents pas de retard (L=1, 2,3).

Retard (Lag)	Radar 1 (avant traitement OOSM) IMM-KF	En séquence (l'optimal) IMM-KF	IMM-OOSM (traitement OOSM) IMM-BI1
1	1.6399	1.3016	1.3578
2	1.6291	1.3691	1.4213
3	1.6559	1.3755	1.5512

Tableau 5.2 : La moyenne des erreurs de position (radar1, en séquence et IMM-OOSM (scénario 2))

Retard (Lag)	Radar 1 (avant traitement OOSM) IMM-KF	En séquence (l'optimal) IMM-KF	IMM-OOSM (traitement OOSM) IMM-BI1
1	1.7669	1.4244	1.5062
2	1.7899	1.5258	1.6041
3	1.7933	1.5458	1.7258

Tableau 5.3 : La moyenne des erreurs de position (radar1, en séquence et IMM-OOSM (scénario 3))

Les résultats de ce tableau ont été obtenus en changeant à chaque fois le pas de retard. On constate finalement que la moyenne des erreurs de position de l'IMM-KF de cas où toutes les mesures arrivent en séquence est meilleur (plus petit), et petite par rapport aux cas de radar1 seul. La moyenne des

erreurs quadratique de position de l'algorithme IMM-BL1 est plus proche au cas où les deux capteurs sont alignés ce qui confirme l'efficacité de l'algorithme IMM-BL1. en cas de changement dans ces paramètres de mouvement (changement de modèle de mouvement) et de retard de mesure au centre de traitement, ce qui veut dire que l'IMM-BL1 arrive à suivre la cible dans tout les cas où il y 'a changement de mouvement et retard de mesure.

Ainsi, la moyenne des erreurs quadratique est augmentée quand le retard est plus grand.

Le tableau 5.3 montre les temps des mesures arrivés de différents pas de retards avec une période d'échantillonnage  $T=1s$ .

L=1	num radar temps	1	1	2	1	2	1	2	1	2	1	2	1	2	1
		0	3	<b>2.5</b>	4	<b>3.5</b>	5	<b>4.5</b>	6	<b>5.5</b>	7	<b>6.5</b>	8	<b>7.5</b>	9
L=2	num radar temps	1	1	1	2	1	2	1	2	1	2	1	2	1	
		0	3	4	<b>2.5</b>	5	<b>3.5</b>	6	<b>4.5</b>	7	<b>5.5</b>	8	<b>6.5</b>	9	
L= 3	num radar temps	1	1	1	1	2	1	2	1	2	1	2	1		
		0	3	4	5	<b>2.5</b>	6	<b>3.5</b>	7	<b>4.5</b>	8	<b>5.5</b>	9		

Tableau 5.4 : le temps d'arrivées des mesures des différents pas de retards

Pour les différents retards ( $L=1, 2, 3$ ) nous remarquons que la mesure de deuxième capteur (la mesure hors séquence) vient après :

- une mesure de premier capteur implique que  $L=1$ .
- deux mesures de premier capteur implique que  $L=2$ .
- trois mesures de premier capteur implique que  $L=3$ .

### 5.5 Conclusion :

Dans ce chapitre, nous avons présenté les résultats de simulation de l'algorithme OOSM (BL1) au cas de poursuite de cibles non manoeuvrantes et l'algorithme IMM-OOSM au cas de la poursuite de cibles manoeuvrantes.

On a pu vérifier à l'aide d'un grand nombre de simulations, que cet algorithme permet effectivement de suivre la cible manoeuvrante par plusieurs capteurs asynchrones (présence des mesures hors séquence).

## CONCLUSION

Nous avons présenté notre travail qui consiste à calculer les estimations de différents paramètres du vecteur d'état de la trajectoire d'une cible modélisée en deux parties. Dans la première partie, la cible (non manœuvrante) se déplace le long d'une trajectoire rectiligne (à une dimension et deux dimensions) à vitesse constante dans une direction donnée. Dans la deuxième partie, la cible (manœuvrante) se déplace le long d'une trajectoire rectiligne à vitesse constante dans une direction donnée, puis la cible opère un virage à droite ou à gauche, et dans les deux parties nous considérons des mesures hors séquence avec différent pas de retard. Dans la première partie, les estimations, la détection et la correction sont faites par un algorithme OOSM (BL1) qui effectue la poursuite de la cible avec différents pas de retard, dans la deuxième partie, nous utilisons l'approche à modèles multiples interagissant associés à un algorithme de traitement OOSM (BL1).

Ce travail nous a permis d'approfondir nos connaissances dans le vaste domaine de la poursuite des cibles. Cela nous a permis d'étudier un grand nombre d'algorithmes de poursuite utilisés à l'heure actuelle pour résoudre un certain nombre de problèmes qui se posent en pratique lorsqu'il s'agit de prévoir les trajectoires de cibles dans des environnements complexes. Nous avons ainsi simulé la poursuite de cibles manœuvrantes avec multi-capteurs grâce à un algorithme qui combine l'approche modèles multiples avec le traitement des mesures hors séquence.

L'analyse des résultats des simulations d'après les différents scénarios que nous avons élaborés, a montré que l'algorithme OOSM de type non séquentiel seul est un bon estimateur des paramètres d'état en cas de mesures hors séquence, mais son efficacité est réduite en présence de manœuvres de la cible.



L'algorithme IMM-BI1 que nous avons testé ensuite et qui est une association d'un algorithme IMM et un algorithme OOSM a permis d'améliorer considérablement les performances du filtre de poursuite dans des situations de virage par exemple. Ceci a été constaté dans toutes les simulations que nous avons effectuées : on a pu vérifier en effet que les résultats sont très proches du cas idéal où toutes les mesures arriveraient dans les délais et que la réaction face à une manœuvre est assez rapide. Cependant, on a pu constater, lorsque le retard des mesures hors séquence augmente, une diminution de l'efficacité du filtre, ce qui signifie que les mesures hors séquences n'apportent plus grand-chose à la poursuite.

Pour prolonger ce travail nous pouvons proposer les perspectives suivantes :

- concernant le problème des mesures hors séquence nous pouvons créer un pseudo piste (à partir de l'OOSM) et fait son alignement temporel avec la trajectoire, puis le fusionne avec celle-ci.
- Pour améliorer les performances des algorithmes étudiés nous proposons d'appliquer les algorithmes OOSM au cas du mouvement non linéaire où on utilise des filtres puissant capable de linéariser les modèles non linéaire parmi eux le filtre de kalman etendu (EKF) et le filtre de kalman sans parfum (UKF)

## APPENDICE A

### LISTE DES SYMBOLES ET DES ABREVIATIONS

C	: Facteur de normalisation
Cov	: Covariance
CT	: Modèle de virage
CT+	: Virage à droite
CT-	: Virage à gauche
CV	: Modèle à vitesse constante
CA	: Modèle à accélération constante
EKF	: Filtre de Kalman Etendu
$E[\cdot]$	: Espérance mathématique
$e_k^-$	: Estimation d'erreurs à priori
$e_k$	: Estimation d'erreurs à posteriori
$F(k)$	: Matrice de transition reliant l'instant $t(k)$ à l'instant
$f\{\cdot\}$	: La densité de probabilité
G	: Le gain de recalage optimal
GMTI	: Indicateur de cible mobile terrestre
GPB1	: Estimateur Pseudo-Bayésien Généralisé De Premier Ordre
GPB2	: Estimateur Pseudo-Bayésien Généralisé De Deuxième ordre
H	: Matrice de mesure
I	: Matrice unité
IMM	: Modèle Multiple Interagissant
KF	: Filtre de Kalman
K	: Gain du filtre de Kalman
$\kappa$	: Notation discrète de temps $\tau$ .
L	: Retard

MSE	: Mean squar error (l'erreur quaratique)
$M_j(k)$	: Modèle j à l'instant k
OOSM	: Out Of Séquence Measurements
OOS	: Out Of Séquence
P	: Matrice de covariance de l'erreur d'estimation
PDF	: Fonction de Densité de Probabilité
P(k)	: Matrice de covariance de l'estimation
$P(k k-1)$	: Matrice de covariance de l'estimation prédite
$P(\cdot)$	: Probabilité
$P_{vv}$	: Covariance de bruit
$P_{xv}$	: Covariance de croisement entre le vecteur d'état et le bruit
$P_{xz}$	: Covariance de croisement entre le vecteur d'état et le vecteur de mesure
Q	: Matrice de covariance du bruit du système
R	: Matrice de covariance du bruit de mesure
R	: Rayon de courbure
S	: La covariance de la retrodiction de mesure
SLAR	: Side Looking Airborne Radar
t	: Temps
$\Delta t$	: Intervalle de temps
$\tau$	: Temps de l'OOSM
$v(k)$	: Vecteur de bruit de mesure au temps t(k)
$w(k)$	: Vecteur de bruit de processus au temps t(k)
$\omega$	: Vitesse angulaire
$x(k)$	: Vecteur d'état du processus au temps t(k)
$\hat{x}(k)$	: Vecteur d'estimation de $x(k)$ au temps t(k)
$\hat{x}(k k-1)$	: Vecteur d'estimation à priori au temps t(k)
$\hat{x}_k^-$	: Estimation d'état à priori
$\hat{x}_k$	: Estimation d'état à priori
$y(k)$	: Vecteur d'état

$z(k)$	: Vecteur de mesure au temps $t(k)$
$\tilde{z}$	: Résidu du filtre de Kalman
$z(\kappa)$	: Vecteur de mesure OOSM au temps $t(\kappa)$
$\theta$	: Direction de la trajectoire
$\gamma$	: L'accélération
$\mu_j$	: Les probabilités des modèles
$\Lambda$	: La fonction de maximum vraisemblance

## REFERENCES

1. Anxi Yu, Liang Diannong, Hu Weidong, Dong Zhen, "A Unified Out-of-sequence Measurements Filter" National University of Defense Technology, 2005.
2. Bar-Shalom, Y, and Li, X. R., and Kirubarajan, T "Estimation with Applications to Tracking and Navigation: Algorithms and Software for Information Extraction",New York: Wiley, 2001.
3. Bar-Shalom.Y, "Update with out-of-sequence measurements in tracking Exact solution", IEEE Transactions on Aerospace and Electronic Systems Vol. 38, No. 3 July 2002.
4. Bar-Shalom.Y, and X. Rong Li, "Estimation and Tracking: Principles, Techniques and Software". Norwood, MA: Artech House, 1993.
5. Bar-Shalom.Y "Update with Out-of-Sequence Measurements in Tracking", April 2000.
6. Bar-Shalom, Y, Mallick.M, Chen.H, and Washburn, R "One-step solution for the general out-of-sequence measurement problem in tracking",In Proceedings of the 2002 IEEE Aerospace Conference, Big Sky, MT, Mar 2002.
7. Bar-Shalom. Y, Chen. H , and Mallick M, "One-step solution for the general out-of-sequence measurement problem in tracking", IEEE Transactions on Aerospace and Electronic Systems, 40, 1 (Jan. 2004), 27—37.
8. Bar-Shalom.Y, Chen, H,"IMM Estimator with Out-of-Sequence Measurements", IEEE transactions on aerospace and electronic systems Vol. 41, No. 1January 2005.
9. Blom, Henk A.P. and Y. Bar-Shalom,"The Interacting Multiple Model Algorithm for Systems with Markovian Switching Coefficients", IEEE Transactions on Automatic Control, 33 (Aug):780–783 (August 1988).

10. Brown R. G, P. Y. C. Hwang, « Introduction to Random Signals and Applied Kalman Filtering », 2eme Edition 1992.
11. Blanc M.C., "combinaison d'estimation : Application à la détection d'obstacles à bord des véhicules routiers intelligents", Thèse de doctorat, Université de Blaise Pascal, juillet 2005.
12. Blom H. A. P, Y. Bar-Shalom, "The Interacting Multiple Model Algorithm for Systems with Markovian Switching Coefficients", IEEE Trans, on AC, Vol.33, No.8, pp.780-783, 1988.
13. Challa , Robin.J ,Evans.X ,Wang ,et Jonathan LEGG, "A fixed- lag smoothing solution to out-of-sequence information fusion problems", Communications in information and systems , Vol. 2, No. 4, pp.325-348, December2002.
14. Challa S, J. Legg and X. Wang. "Track-to-Track Fusion of Out-of-Sequence Tracks", In Proceedings of the Fifth International Conference on Information Fusion, Annapolis,Maryland, USA, July, 2002, pp. 919–926.
15. Challa S, Evans R, and Wang X "A Bayesian solution and its approximations to out-of-sequence measurement problems".Journal of Information Fusion, 4, 3 (Sept. 2003), 185—199.
16. Chih-Chung Ke , "Literature survey on ground target tracking problems ",army Communications and Electronics Command, REPORT NO. CMIF-3-99, August 1999.
17. Djouadi M.S, "poursuite de cibles manoeuvrantes par vision active ", Thèse de doctorat, Ecole Nationale polytechnique, Decembre, 2005.
18. Durrant Hugh Whyte, "A Beginners Guide to Decentralised Data Fusion", Australian Centre for Field Robotics The University of Sydney NSW 2006, Australia, July 20, 2000.
19. Duncan Smith and Sameer Singh,"Approaches to Multisensor Data Fusion in Target Tracking",A Survey, IEEE transactions on knowledge and data engineering, vol. 18, No. 12, December 2006.
20. Darricau Jacques « Radars, Concepts et fonctionnalités », technique de l'ingénieur E 6 660.

21. Grewal Mohinder S, Angus P Andrews "Kalman Filtering Theory and Practice ", 1993.
22. Gauvrit.H, "extraction multi-pistes : approche probabiliste et approche combinatoire, thèse de doctorat", Université de Rennes 1, Novembre 1997.
23. Hilton R. D, Martin D. A, Blair W. D., "Tracking with Time-Delayed Data in Multi sensor Systems". August 1993.
24. Henk A.P, Blom Edwin, A. Bloem, "Exact Bayesian filter and joint IMM coupled PDA tracking of maneuvering targets from possibly missing and false measurements".
25. Hong L, Cong S, and Wicker. D, "Multirate interacting multiple model (MRIMM) filtering with out-of-sequence GMTI data". In IEE Proceedings– Radar Sonar Navigation, 150, 5 (Oct. 2003), 333—343.
26. Jonathan A. Legg "Distributed Multisensor Fusion System and Evaluation Issues", Defence Science and Technology Organisation, PO Box 1500, October 2005.
27. Jason L. Williams, Flight Lieutenant, RAAF AFIT/GE/ENG/03-19, "Gaussian mixture reduction for tracking multiple maneuvering targets clutter". Air Force Institute of Technologies. Department of the Air Force Air University.
28. Jacques Darricau " Radars, Principes et éléments de base", technique de l'ingénieur E 6 650.
29. Kalman, R. E "A New Approach to Linear Filtering and Prediction Problems", Transaction de la technologie de base pp. 35-45 (March 1960).
30. Keshu Zhang X, Rong Li ,Huimin Chen et Mahendra Mallick "Multi-Sensor Multi-Target Tracking with Out-of-Sequence Measurements", Department of Electrical Engineering, University of New Orleans,2003
31. T. Kirubarajan, Y. Bar-shalom, K. R. Pattipati, I. Kadar, "Ground Target Tracking with Variable Structure IMM Estimator", IEEE transactions on aerospace and electronic systems vol. 36, NO. 1 january 2000.
32. Karlsson Rickard, "Simulation Based Methods for Target Tracking", these de doctorat, Department of Electrical Engineering, Linköpings universitet, SE{581 83 Linköping, Sweden,2002.

33. Li, X. R et Bar-Shalom, Y, "Multitarget-Multisensor Tracking: Principles and Techniques", 1995.
34. Mallick M, S.J. Krant, Y. Bar-Shalom "Multisensor Multi-target Tracking using Out-of-Sequence Measurements", International Conf July 2002.
35. Mallick Mahendra, Alan Marrs, "Comparison of the KF and Particle Filter Based Out-of-Sequence Measurement Filtering Algorithms", ISIF 2003.
36. Mallick Mahendra, Stefano Coraluppi, and Yaakov Bar-Shalom, "Comparison of Out-of-sequence Measurement Algorithms in Multi-platform Target Tracking", Proc. 2001 International Conf. Information Fusion, Montreal, QC, Canada, August 2001.
37. Mariton M, "Pistage de cibles manoeuvrantes : synthèse et rapport de l'imagerie", traitement du signal, volume10, n°2.
38. Mauthner Moritz, Elmenreich Wilfried, Kirchner Alexander,"Analysis of Sensor and Fusion Schedules of a Time-Triggered Sensor Fusion System".
39. MORSLY Yacine, "Contribution à la mise en oeuvre de techniques d'association de données pour la poursuite de cibles manoeuvrantes " Thèse de magister en Automatique, Ecole militaire polytechnique 2006.
40. Novoselsky Akiva, Shlomo E. Sklarz and Miya Dorfan, "Track to track Fusion using Out-of-Sequence Track Information ",Elta Systems Ltd. Image Intelligence Exploitation Department (section 6174) Image Intelligence and Radar Division, Ashdod, Israel.
41. Rhéaume François , Benaskeur Abder Rezak "Forward Prediction-based Approach to Target-Tracking with Out-of-Sequence Measurements"Decision Support Systems Section Defence R&D Canada – Valcartier,2008.
42. SAIDANI Wissem, "Poursuite de cibles multiples par l'utilisation d'un réseau de capteurs",Thèse de magister en Automatique,Ecole militaire polytechnique 2008.
43. SEBBAGH Abdennour, "Utilisation des informations visuelles pour la poursuite de cibles manoeuvrantes à l'aide de l'approche IMM", Mémoire de magistère, EMP, 2004.



44. Simon R. Maskell, Richard G. Everitt, Robert Wright, Mark Briers "Multi-target out-of-sequence data association: Tracking using graphical models", QinetiQ, Malvern Technology Centre, St. Andrews Road, Malvern WR14 3PS, Worcestershire, UK, 1 July 2005.
45. Shawn Michael Herman, "A particle filtering approach to joint passive radar tracking and target classification". University of Illinois at Urbana-Champaign, 2002.
46. Suihua Lu, Aubrey B. Poore, Brian J. Suchomel, "Network-Centric MFA Tracking Architectures", ISIF, 2002.
47. Semerdjiev Emil, Mihaylova Ludmila, X. Rong Li, "Variable- and Fixed-Structure Augmented IMM Algorithms Using Coordinated Turn Model".
48. Schmaedeke Wayne and Kastella Keith, "Sensor Management using Discrimination Gain and Interacting Multiple Model Kalman Filters", Lockheed-Martin Tactical Defense Systems – Eagan.
49. Wang, X., and Challa, S. Augmented state IMM-PDA for OOSM solution to maneuvering target tracking in clutter. In Proceedings of Proceedings of Radar 2003 International Conference, Adelaide, Australia, Sept. 2003, 479— 485.
50. Zhang .Keshu, X. Rong Li, and Yunmin Zhu, "Optimal Update With Out-of-Sequence Measurements", IEEE transactions on signal processing, Vol. 53, No. 6, June 2005.
51. ZHOU WenHui, LI Lin, CHEN GuoHai1 et YU AnXi, « Optimality analysis of one-step OOSM filtering algorithms in target tracking, Science in China Press, Springer-Verlag, Sci China Ser F-Inf Sci, April 2007, vol. 50, No. 2, 170-187.
52. Zhang, K. S, X. R, et, Y. M, «Optimal update with out-of-sequence observations for distributed filtering » Annapolis, MD, July 2002