

République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Ecole Nationale Polytechnique
Département d'Electronique

Thèse de Doctorat

Présenté par

Mohand Saïd DJOUADI

(Ingénieur d'Etat ENITA)

Titre de la thèse

Poursuite de Cibles Manoeuvrantes par Vision Active

Soutenue le, 14/12/2005, devant le jury composé de:

Président:	M.S. Boucherit	Professeur ENP
Examineur:	M. Hamerlain	Directeur de Recherche CDTA
Examineur:	L.M. SI Mohamed	M.C. EMP
Examineur:	A. Ould Ali	M.C. EMP
Examineur:	F. Merazka	M.C. USTHB
Rapporteur:	D. Berkani	Professeur ENP

A mes Parents

A ma Femme

A mes Enfants

Remerciements

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

Mes sincères remerciements à Monsieur Mohamed Seghir BOUCHERIT, Professeur à l'Ecole Nationale Polytechnique, pour avoir accepté de présider mon jury de thèse.

Mes remerciements vont aussi à:

Monsieur Mustapha HAMERLAIN, Directeur de Recherche au CDTA,
Monsieur Abdelaziz OULD ALI, Maître de Conférences à l'EMP,
Monsieur Lotfy Mokhtar SI MOHAMED, Maître de Conférences à l'EMP,
Mademoiselle Fatiha MERAZKA, Maître de Conférences à l'USTHB.

Pour avoir bien voulu participer à mon jury de thèse et juger ma contribution au domaine de la poursuite de cibles et de la vision.

Table des Matières

Introduction générale	1
------------------------------------	---

Chapitre I

Etat de l'Art de l'Asservissement Visuel

I.1 Introduction.....	4
I.2 Principe de l'asservissement visuel (AV).....	4
I.2.1 Asservissement visuel sur objet statique.....	4
I.2.1.1 "Look and Move" Statique	5
I.2.1.2 "Look and Move" Dynamique	6
I.2.2 Asservissement visuel sur objets en mouvement	6
I.3 Classification de l'asservissement visuel.....	6
I.3.1 Asservissement où la caméra est extérieure.....	7
I.3.2 Asservissement «eye in hand ».....	8
I.3.3 Asservissement Visuel Indirect	8
I.3.4 Asservissement Visuel Direct.....	9
I.4 Principe de la commande par fonction de tâche.....	10
I.5 Asservissement visuel 3D.....	10
I.6 Asservissement Visuel 2D.....	11
I.7 Asservissement Visuel d2D/dt.....	12
I.8 Conclusion.....	13

Chapitre II

Estimation Robuste aux Brusques Ruptures de Mouvements

II.1 Introduction.....	14
II.2 Systèmes stochastiques avec des sauts inconnus.....	15
II.2.1 Formulation de l'approche dans le cas linéaire.....	16
II.2.2 Calcul de la probabilité de détection.....	20
II.3 Extension de l'approche au cas non linéaire.....	20
II.4 Modélisation des trajectoires.....	21
II.4.1 Modèle d'une droite.....	22
II.4.2 Modèle d'un cercle.....	24
II.5 Principe de la batterie de filtres.....	25
II.5.1 But.....	26
II.5.2 Principe de la méthode	26
II.6 Simulation et commentaires.....	27
II.6.1 Filtrage de Kalman sans test de GLR	28
II.6.1.1 Cas d'un mouvement rectiligne à vitesse constante	28
II.6.1.2 Cas d'un mouvement rectiligne à accélération constante.....	29

II.6.1.3 Cas d'un mouvement circulaire à vitesse constante	31
II.6.1.4 Cas d'un mouvement circulaire à accélération constante	32
II.6.2 Batterie de filtres	34
II.6.2.1 cas d'un mouvement rectiligne à vitesse constante.....	34
II.6.2.2 cas d'un mouvement circulaire à vitesse constante	35
II.6.3 Filtre de Kalman avec test de GLR	36
II.6.3.1 Cas de sauts en vitesse sur une trajectoire rectiligne.....	36
II.6.3.2 Cas de sauts en accélération sur une trajectoire rectiligne	37
II.6.3.3 Cas de sauts en vitesse sur une trajectoire circulaire	38
II.6.3.4 Cas de sauts en accélération sur une trajectoire circulaire.....	40
II.7 Conclusion.....	41

Chapitre III

Approche Modèles Multiples pour la Poursuite de Cibles Manoeuvrantes

III.1 Introduction.....	43
III.2 Estimation à Modèles Multiples.....	43
III.2.1 Approche à Modèles Multiples (cas de non changement de modèles)	44
III.2.1.1 Calcul des probabilités des modèles.....	45
III.2.1.2 Calcul des estimés combinés	46
III.2.2 Approche Modèles Multiples (cas avec changement de modèles).....	47
III.3 Estimateur Pseudo-Bayésien Généralisé de Premier Ordre (GPB1).....	50
III.3.1 Algorithme GPB-1	52
III.4 Estimateur Pseudo-Bayésien Généralisé de Deuxième ordre (GPB-2).....	53
III.4.1 Algorithme GPB-2	55
III.5 Estimateur à Modèle Multiple Interagissant (IMM).....	56
III.6 Conclusion.....	61

Chapitres IV

Extension de l'IMM au Cas de Modèles Non Linéaires

IV.1 Introduction.....	62
IV.2 Principe du filtre.....	63
IV.2.1 Transformation d'incertitude	63
IV.2.2 Filtre de Kalman sans parfum (Unscented Kalman Filter: UKF)	65
IV.2.2.1 Transformation sans parfum	65
IV.2.2.2 Filtre sans parfum	67
IV.2.2.3 Filtre de Kalman sans parfum normalisé (Scaled Unscented Kalman Filter: SUKF).....	68
IV.3 Algorithme de poursuite IMM à base de l'UKF (IMMUKF)	71
IV.3.1 Mélange d'estimé pour le modèle j	71
IV.3.2. Filtrages parallèles	72
IV.3.3 Mise à jour de la probabilité du modèle j	73

IV.3.4 Estimation combinée	73
IV.4 Résultats de Simulation.....	74
IV.4.1 Modélisation des trajectoires et du mouvement des cibles.....	74
IV.4.1.1 Mouvement rectiligne à vitesse constante	74
IV.4.1.2 Mouvement rectiligne à accélération constante	76
IV.4.1.3 Mouvement circulaire à vitesse constante.....	77
IV.4.1.4 Mouvement circulaire à accélération constante	78
IV.4.2 Simulation	79
IV.4.2.1 Paramètres utilisés dans les algorithmes IMM-UKF et IMM-EKF	79
IV.4.2.2 Scénarii.....	81
IV.4.2.3 Interprétation des résultats	94
IV.5 Conclusion	95
Conclusion et Perspectives	96
Annexe A	98
Annexe B	99
Bibliographie	101

Introduction générale

Vers la fin des années 60, des laboratoires de recherche de renoms tels que le MIT (Massachusetts Institute of Technology), le SRI (Stanford Research Institute) ou encore l'université d'Edinbourg ont lancé de grands projets de recherche dont le maître mot était "*Robots intelligents*".

Il est en réalité difficile de parler véritablement de l'intelligence d'une machine ou d'un robot, un terme plus approprié serait l'autonomie, dans le sens où les motivations des roboticiens, sont de fabriquer une machine versatile pouvant s'adapter aux modifications de son environnement de travail ou d'évolution. Une des solutions pour cette adaptation est l'utilisation de capteurs d'environnement (caméra, laser, ultrasons,...), qui sont communément appelés capteurs extéroceptifs, permettant au robot de prendre en compte toute modification ou toute évolution de son environnement. Rapidement la caméra s'est avérée être le capteur extéroceptif le plus performant et fournissant une très riche information. L'intégration des données fournies par la caméra (information visuelle) au niveau de la chaîne de commande de robots manipulateurs ou mobiles a permis l'émergence d'un nouveau type de commande qui porte de nom d'asservissement visuel (AV) et continue de faire l'objet d'attraction de plusieurs laboratoires de recherche en robotique à travers le monde depuis la fin des années 80.

Les différents travaux en asservissement visuel s'intéressent soit à des objets statiques, soit à des objets mobiles. Concernant les objets statiques, il s'agit de réaliser une tâche de positionnement, généralement pour des applications d'inspection, d'assemblage ou de préhension. Par contre, pour des objets en mouvement, il s'agit de réaliser une tâche de poursuite. La réalisation de telles tâches est alors plus délicate à effectuer puisqu'elle nécessite d'estimer le mouvement des objets cibles à suivre. Les applications des tâches de poursuite concernent une variété de domaines, notamment, la télésurveillance pour la sécurisation d'organismes importants ou stratégiques (ministères, usines, champs pétroliers, etc...), la robotique manufacturière pour des tâches de montage automatique au défilé, supprimant ainsi la nécessité d'arrêter les chaînes de montage pour la fixation de pièces supplémentaires, et la surveillance du territoire contre toute intrusion ennemie, en effet le capteur de vision est utilisé comme moyen passif (n'émettant aucune énergie pouvant être détectée ou repérée par la cible) pour la détection et la poursuite de toute cible rentrant dans son champ de couverture.

Le sujet abordé dans cette thèse traite de la poursuite de cibles manoeuvrantes (changement brusque au niveau de la nature du mouvement), en d'autres termes il s'agit de proposer un algorithme efficace d'estimation de mouvement d'une cible, capable d'intégrer rapidement tout changement

Brusque au niveau du modèle de mouvement ou de trajectoire de la cible afin d'assurer le suivi de cette dernière quelque soient ses tentatives de décrochage du processus de poursuite.

Pour résoudre le problème d'estimation du mouvement de cibles manoeuvrantes, deux approches sont généralement citées au niveau de la littérature:

- ✓ La première approche [41] consiste à utiliser la mesure pour estimer les paramètres inconnus de manoeuvre (des méthodes employant souvent des fenêtres de type glissant), et corriger les états estimés en utilisant ces paramètres. En général, c'est la technique du test d'hypothèse qui est utilisée, où grâce au rapport du maximum de vraisemblance (GLR: Generalized Likelihood ratio), on estime, l'instant de l'apparition du saut au niveau d'une des composantes du vecteur d'état, l'amplitude du saut et enfin il est procédé à la correction des estimées en tenant compte de ce dernier.
- ✓ La deuxième approche [12] consiste à utiliser une banque parallèle d'estimateurs, chacun accordé à une condition de fonctionnement différente, et puis de combiner les sorties dans une estimation moyenne pondérée basée sur l'exécution apparente de chaque filtre élémentaire. Pratiquement toutes les techniques à modèles multiples, partagent cette 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.

Malgré l'intérêt avéré de ces deux approches, ces dernières souffrent de nombreuses limitations et de nombreux problèmes dont nous pouvons citer:

- ✓ La première approche considère que la manoeuvre ne peut se manifester que sous forme d'un brusque changement au niveau d'un des paramètres du modèle de mouvement considéré, question: qu'en est il du cas où la cible change complètement de modèle de mouvement?
- ✓ La seconde approche considère souvent des modèles linéaires de mouvement de la cible, question: qu'en est il du cas où ces modèles sont non linéaires?

Notre contribution, consiste en la mise au point et la proposition d'un algorithme d'estimation de mouvement efficace capable de résoudre les problèmes sus cités et qui restent en suspens, c'est-à-dire de résoudre le problème de poursuite de cibles fortement manoeuvrantes tout en considérant le cas de modèles non linéaires et des changements intempestifs et abrupts au niveau de ces derniers.

La présentation de notre travail respecte le plan suivant :

Nous commençons par faire un état de l'art des travaux récents en asservissement visuel, ceci dans le but de cerner le domaine dans lequel ce travail apporte une contribution.

Dans le second chapitre, nous présentons la première approche d'estimation de mouvement basée sur le test du maximum de vraisemblance généralisé (Generalised Likelihood Ratio:GLR) avant de décrire le formalisme mathématique des modèles de mouvement et de trajectoires que nous avons élaboré pour les besoins de notre travail, et présenter les résultats de simulations de l'application du test du GLR pour la détection et la compensation de sauts abrupts au niveau d'un des paramètres des modèles considérés.

Au troisième chapitre, nous décrivons la seconde approche d'estimation de mouvement et de poursuite de cibles basée sur le choix de plusieurs modèles de mouvements possibles, plusieurs variantes seront alors présentées, l'approche Modèles Multiples Interactifs (IMM: Interacting Multiple Model) sera davantage examinée étant donné ses différents avantages et son importance au niveau de l'algorithme d'estimation de mouvement que nous avons mis en œuvre.

Le dernier chapitre, quant à lui, sera consacré à la présentation de notre algorithme dédié à la poursuite de cibles fortement manoeuvrantes, tout en montrant les probants résultats de simulation de plusieurs scénarii où nous avons considéré des manoeuvres très importantes de la cible suivie.

Enfin nous terminerons par une conclusion situant ce présent travail, les résultats obtenus et les possibles orientations futures.

Chapitre I

Etat de l'Art de l'Asservissement Visuel

I.1 Introduction

Le développement spectaculaire réalisé ces dernières années dans la technologie des capteurs de vision a permis l'utilisation effective des informations visuelles dans la chaîne de commande des robots manipulateurs ou mobiles. Comme conséquence directe, l'amélioration de l'exécution des tâches robotiques. En effet, il est possible de tenir compte des incertitudes et/ou des changements dans l'environnement du robot (exemple, compenser des erreurs de modélisation et de calibration dans les tâches de positionnement, ou suivre et saisir des objets convoyés sur un tapis roulant,...). L'opération consistant à intégrer ce type de données au niveau de la boucle de commande ou d'asservissement porte le nom d'asservissement visuel.

En utilisant une caméra embarquée, les techniques d'asservissement visuel permettent de fournir une interaction directe entre la position de l'effecteur du robot et son environnement. Il en résulte une commande plus précise et plus robuste en présence d'incertitudes et d'erreurs de modélisation.

I.2 Principe de l'asservissement visuel (AV)

Le principe de l'asservissement visuel consiste à prendre en compte des informations visuelles issues d'une ou plusieurs caméras dans la boucle de commande d'un robot afin d'en contrôler le mouvement.


I.2.1 Asservissement visuel sur objet statique

L'utilisation de l'information visuelle dans les systèmes robotiques a souvent été fortement contrainte par les ressources de puissance de calcul. A cette époque, seule une exploitation en *boucle ouverte* de la mesure de vision était possible.

La technique consistait à prendre une image de la scène, puis à la traiter, et enfin à déplacer le robot à l'endroit désiré en fonction de la mesure visuelle, cette approche est dénommée « Static Look and Move », (voir figure (I.1)-a). Outre son extrême lenteur à réagir à des modifications de l'environnement, cette technique est très sensible aux erreurs de modélisation de la caméra et du robot [6,18].

Au cours de ces dix dernières années, les progrès en matière de puissance de calcul des ordinateurs ont permis aux applications robotiques basées sur la vision de devenir de plus en plus temps réel. La période de mesure des systèmes de vision diminuant (1 milliseconde pour les plus rapides actuellement [61]), il est désormais possible d'inclure la mesure extraite de l'image dans une boucle d'asservissement. On parle alors du « Dynamic Look and Move » comme le montre la figure ((I.1)-b).

La tâche robotique à effectuer peut donc être redéfinie comme une trajectoire référencée par rapport à la scène. Tout mouvement de la scène agit comme une perturbation pour l'asservissement qui tend à l'annuler [14].



a) “Static Look and Move”

b) “Dynamic Look and Move”

Figure (I.1) : La technique Look and Move

I.2.1.1 "Look and Move" Statique

Dans le cas statique, la localisation 2D issue de l'analyse de l'image conduit à l'évaluation de la situation de l'objet par rapport au capteur. Cette connaissance permet la commande du robot dans l'espace cartésien, dans le but de faire évaluer la situation entre la caméra et l'objet.

Le contrôle du robot est assuré par un asservissement classique en position dans l'espace cartésien. Le mode de fonctionnement consiste en un enchaînement séquentiel des deux étapes suivantes :

- ✓ la caméra acquiert une image, un algorithme en extrait les informations choisies et en déduit une estimation de la situation entre la caméra et l'environnement.
- ✓ la loi de commande calcule un déplacement de la caméra en fonction de l'erreur entre la situation actuelle et la situation à atteindre, traduit ce déplacement dans l'espace cartésien sous la forme de consigne dans l'espace articulaire à l'aide du modèle géométrique inverse ; le robot exécute ce déplacement et attend l'arrêt de la caméra avant l'acquisition d'une nouvelle image.

Théoriquement, une seule itération est nécessaire pour asservir la caméra à la situation voulue, malheureusement, les différentes erreurs qui peuvent s'introduire dans ce processus nécessitent une répétition de

la séquence « Look and Move » jusqu'à l'obtention d'une erreur entre la situation courante et la situation souhaitée inférieure à celle spécifiée lors de la définition de la tâche. Trois types d'erreur peuvent intervenir dans ce processus:

- ✓ Les erreurs d'extraction des informations visuelles inhérentes à tout traitement dans l'image.
- ✓ Les erreurs d'estimation de la situation entre la caméra et son environnement, dues aux inévitables erreurs de calibration de la caméra.
- ✓ Les erreurs du modèle du robot, dues aux erreurs de construction ou à une modélisation imprécise, qui impliquent que la situation réelle de la caméra ne correspondent pas exactement avec celle qui est mesurée.

I.2.1.2 "Look and Move" Dynamique

La structure « Look and Move » dynamique est identique à celle du « Look and Move » statique décrite précédemment. La principale différence réside dans le fait que cette dernière fonctionne en boucle ouverte, tandis que la première fonctionne en boucle fermée, en d'autres termes la boucle d'asservissement est refermée sur le calcul, par traitement d'image, de la position de l'objet dans le repère caméra (Figure (I.1)).

I.2.2 Asservissement visuel sur objets en mouvement

Comme tout processus évoluant en boucle fermée, l'asservissement visuel ne déroge pas aux impératifs de stabilité et de temps de réponse. Ainsi, l'utilisation de l'AV sur un objet mobile va forcément impliquer un certain retard, un trainage quant à la convergence de la mesure vers la consigne, la caméra portée par le robot se contentant alors de « poursuivre » les primitives image. Comme les données fournies par le capteur qu'est la caméra (indices visuels) concernent seulement l'image, c'est la dynamique dans l'image qui devient intéressante, plusieurs méthodes de prédiction de position pour des modèles de mouvement usuels, et des méthodes de détection de changement de type de mouvement, sont alors proposées.

I.3 Classification de l'asservissement visuel

Les systèmes de commande utilisant la vision sont généralement classés selon deux (02) critères :

- ✓ Selon que la caméra soit externe au robot, ou solidaire à son effecteur, on parlera alors de configuration avec caméra extérieure ou de configuration "eye in hand".
- ✓ Selon que l'on utilise le contrôleur, fourni par le constructeur, du robot, on parlera alors d'AV *indirect*, ou que l'on conçoive notre

propre contrôleur indépendamment de celui du constructeur, on parlera alors d'*AV direct* (cette dernière suppose l'accès aux différents codeurs et actionneurs du robot).

I.3.1 Asservissement où la caméra est extérieure

La caméra est positionnée de manière à ce que l'organe terminal (effecteur) et les objets situés dans l'espace de travail du robot soient dans son champ de vision. Elle peut être fixée ou montée sur un autre système mécanique. Dans cette configuration, l'information visuelle permet non seulement la mesure de l'attitude ou le changement d'attitude d'un objet situé dans l'espace de travail du robot, mais la mesure de l'attitude ou du changement d'attitude de l'organe terminal. La figure (I.2) décrit la configuration où la caméra est extérieure au robot qui est asservi.




Figure (I.2) : Configuration où la caméra est extérieure

I.3.2 Asservissement «eye in hand »

C'est la configuration la plus répandue. La caméra est attachée à l'organe terminal de manière à ce que les objets situés dans l'espace de travail soient dans son champ de vision (Figure (I.3)). Dans cette configuration, la caméra est utilisée pour mesurer l'attitude ou changement d'attitude d'un objet par rapport à l'organe terminal du robot.




Figure (I.3) : la configuration "eye in hand"

I.3.3 Asservissement Visuel Indirect

La plupart des applications d'asservissement par vision réalisées jusqu'à ce jour sont en fait des asservissements visuels indirects. Outre le fait qu'il est parfois matériellement difficile de modifier le contrôleur fourni par le constructeur, son intégration dans la boucle de vision permet de simplifier grandement la conception du système.

En effet, ce dernier est souvent pourvu d'une interface de dialogue avec un système extérieur permettant d'avoir accès à toutes sortes de fonctions: contrôle de vitesse cartésienne dans différents repères, gestion des singularités, gestion des sécurités... etc.

Néanmoins, une telle architecture n'est absolument pas adaptée à un asservissement par vision visant à atteindre de bonnes performances dynamiques. En effet, lorsque la cadence d'échantillonnage de l'information visuelle est suffisamment grande par rapport aux constantes de temps mécaniques du robot, des boucles internes de position ne peuvent que

ralentir l'asservissement par vision par l'introduction de retards supplémentaires [6].

Aussi, ce type d'asservissement correspond à des applications dont le but recherché n'est autre que la rapidité. Le schéma dans la figure (I.4) montre la structure en question.

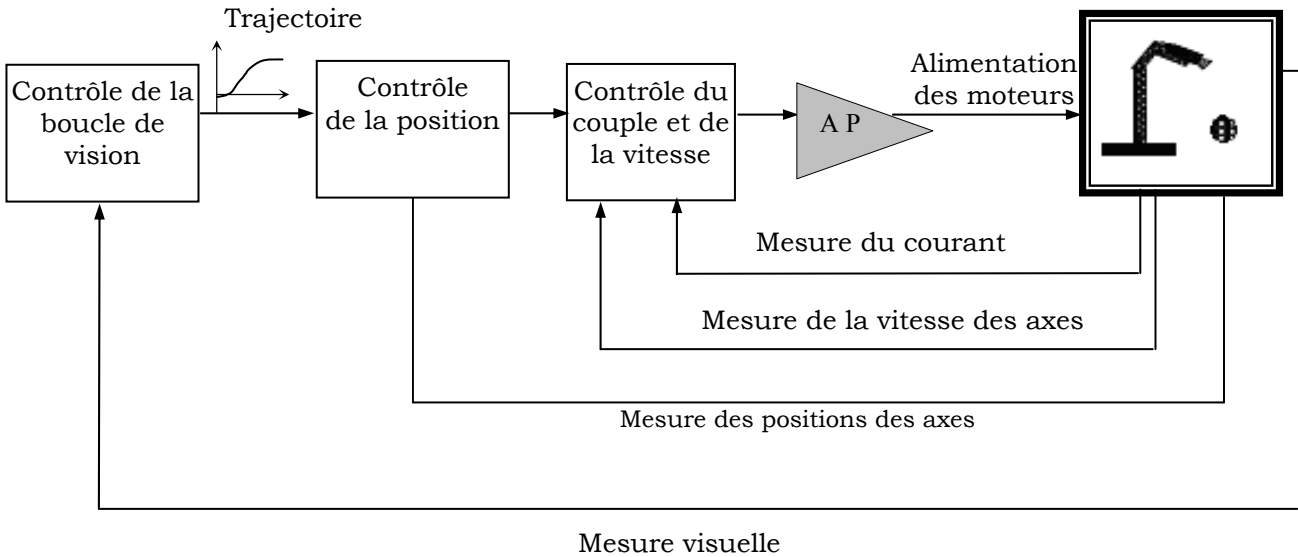


Figure (I.4) : Structure d'un Asservissement Visuel indirect

I.3.4 Asservissement Visuel Direct

L'asservissement visuel direct n'a pas connu un grand succès, mais il devrait bientôt se généraliser dans un proche avenir. En effet, la croissance exponentielle de la puissance de calcul conjuguée avec l'apparition de systèmes de vision de plus en plus rapides pousse à adopter une telle structure de commande afin de mieux tirer profit des possibilités dynamiques offertes par le robot [6,18].

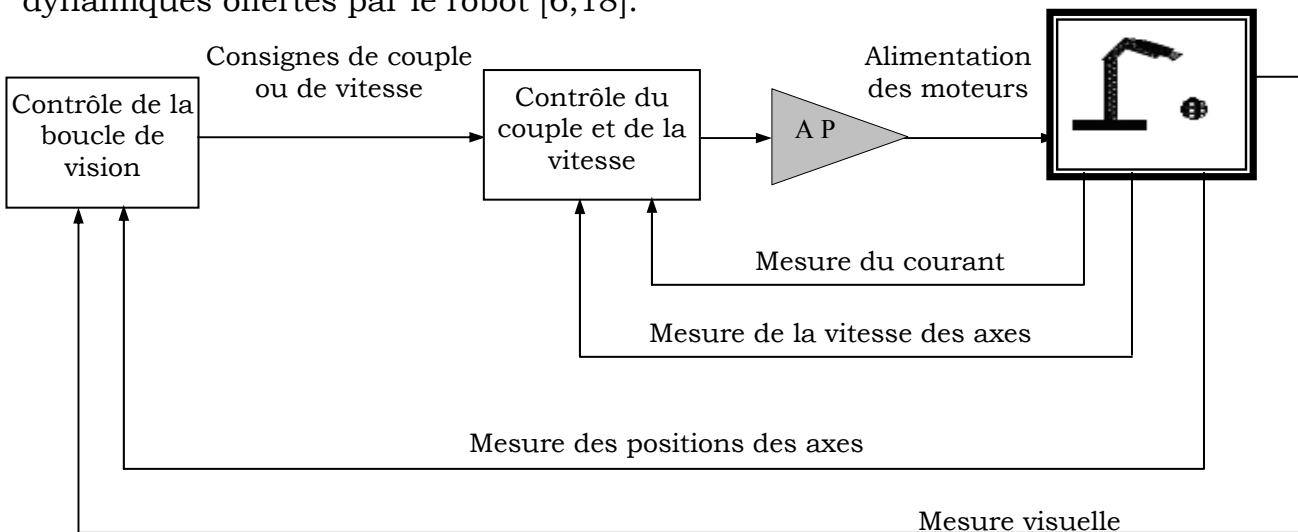


Figure (I.5) : Structure d'un Asservissement Visuel direct

I.4 Principe de la commande par fonction de tâche

Généralement, une tâche robotique peut être exprimée comme la régulation, sur un certain horizon temporel, d'une fonction $e(\mathbf{q},t)$ appelée *fonction de tâche* (où \mathbf{q} est le vecteur de coordonnées articulaires du robot). Les fonctions de tâches classiques sont :

- $e(\mathbf{q},t) = \mathbf{q} - \mathbf{q}^*(t)$ où $\mathbf{q}^*(t)$ est une trajectoire désirée dans l'espace articulaire.
- $e(\mathbf{q},t) = \mathbf{r}(\mathbf{q}) - \mathbf{r}^*(t)$ où $\mathbf{r}^*(t)$ est une trajectoire désirée dans l'espace cartésien.
- $e(\mathbf{q},t) = \mathbf{s}(\mathbf{q}) - \mathbf{s}^*(t)$ où $\mathbf{s}^*(t)$ est une trajectoire désirée dans l'espace du capteur.

En introduisant cette nouvelle notion de fonction de tâche, il est clair qu'une autre classification peut être faite sur la base du choix de la fonction de tâche. En effet, nous pouvons par exemple construire cette fonction de la manière suivante :

- $e(\mathbf{q}) = \mathbf{r}(\mathbf{s}(\mathbf{q})) - \mathbf{r}(\mathbf{s}^*(\mathbf{t}))$, la position \mathbf{r} de l'effecteur du robot est estimée à partir des informations visuelles. Cette approche est appelée *asservissement visuel 3D* car le contrôle de la caméra se fait dans l'espace cartésien [6].
- $e(\mathbf{q},t) = C(\mathbf{s}(\mathbf{q}) - \mathbf{s}^*(\mathbf{t}))$ où C est une matrice qui permet de tenir compte d'une éventuelle redondance d'informations. La fonction de tâche est construite à partir de la différence entre les informations courantes et désirées. Cette approche est appelée *asservissement visuel 2D* car le contrôle de la caméra se fait dans l'image.

Ces deux méthodes ne sont pas les seules existantes, mais elles sont les plus répandues dans la littérature. Les autres méthodes que nous citerons dans ce travail sont, en réalité, des dérivées de ces deux méthodes, comme l'*asservissement visuel 2D 1/2* et l'*asservissement visuel d2D/dt*. Enfin, toute ces méthodes seront plus loin détaillées .

I.5 Asservissement visuel 3D

Dans un asservissement 3D, la référence est exprimée sous la forme d'une attitude. L'attitude d'un repère par rapport à un autre est définie par une translation et une rotation.

Dans la configuration "*eye in hand*", il s'agit de l'attitude \mathbf{P}^* d'un repère lié à un objet vu par la caméra par rapport à un repère lié à l'organe terminal. La mesure utilisée dans l'asservissement est une estimation $\hat{\mathbf{P}}$ de l'attitude courante \mathbf{P} entre l'organe terminal et l'objet.

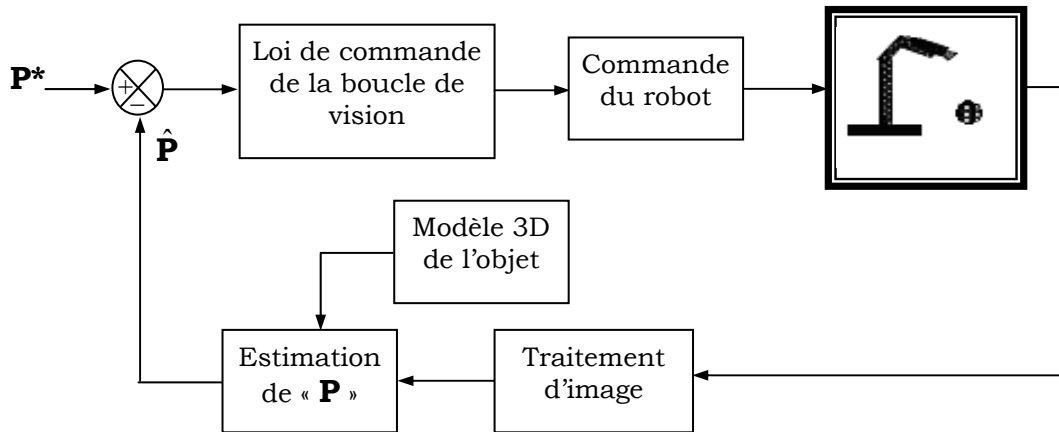


Figure (I.6) : Structure d'un Asservissement Visuel 3D

I.6 Asservissement Visuel 2D

Dans un asservissement 2D, le signal de référence est exprimé sous la forme de primitives visuelles dans l'image. Une primitive est une forme géométrique élémentaire (point, segment de droite, portion d'ellipse,...). Elle sert à modéliser la projection d'un objet dans le plan image.

La plupart des travaux qui traitent de l'asservissement 2D utilisent des primitives constituées de points. Ces points peuvent par exemple être situés à l'intersection de segments dans l'image ou encore être extraits du centre de gravité de la projection de disques. En fait, les cibles les plus couramment rencontrées sont simplement constituées de plusieurs disques coplanaires. De telles cibles ont l'avantage de nécessiter un temps de traitement d'image faible.

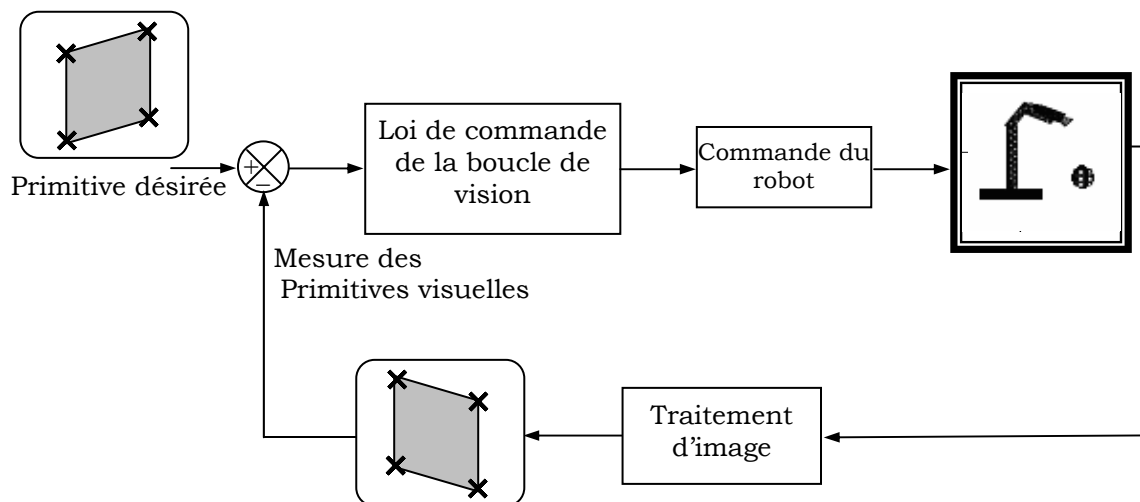


Figure (I.7) : Structure d'un Asservissement Visuel 2D

Un des principaux avantages de l'asservissement 2D est qu'il n'est pas nécessaire de connaître un modèle de la cible. Dans le cas où les primitives sont des points, si nous disposons d'une estimation de la profondeur de la cible (c'est à dire son éloignement par rapport à la caméra suivant l'axe optique), les informations contenues dans l'image suffisent à déterminer le déplacement de la cible par rapport à la caméra.

Différentes techniques peuvent être utilisées pour estimer cette profondeur. Lorsqu'il s'agit d'une expérience de suivi de cible, nous faisons souvent deux approximations sur la profondeur : nous considérons que celle-ci ne varie pas avec le temps et nous estimons que tous les points de la cible ont la même profondeur (la taille de la cible est souvent négligeable par rapport à la distance entre la cible et la caméra). Il est également possible de recourir à un algorithme adaptatif qui permet d'estimer en ligne la profondeur de la cible.

I.7 Asservissement Visuel d2D/dt

Les méthodes que nous avons décrites jusqu'à présent reposent sur l'utilisation d'informations visuelles géométriques (coordonnées de points, paramètres représentant l'image d'une droite, ...). Les contraintes imposées sont donc que ces primitives géométriques existent dans la scène, mais surtout qu'il est possible de les extraire et de les suivre par traitement d'image à une cadence plus élevée afin de conserver la robustesse et la stabilité des lois de commande [7].

Actuellement, peu de systèmes fiables existent et sont limités soit au suivi de segments, soit au suivi de points caractéristiques ou de formes simples. En pratique, nous utilisons le plus souvent des marqueurs disposés sur la scène observée afin d'extraire les positions de leur projection perspective dans l'image.

Des travaux récents ont permis de supprimer ces contraintes fortes par l'emploi d'informations visuelles dynamiques [18]. Ce type d'asservissement visuel utilise une vitesse relative entre la caméra et la cible comme grandeur asservie. La référence est définie dans le plan image par un champ de vitesse des points (voir Figure (I.8)).




Figure (I.8) : Exemple de champ de vitesse désiré (à gauche)
et mesuré (à droite)

Le principe de la commande consiste alors à contrôler les mouvements de la caméra de telle sorte que le mouvement 2D mesuré atteigne un champ de vitesse désiré, d'où l'appellation d'*asservissement visuel $d2D/dt$* .

I.8 Conclusion

Ce présent chapitre se veut être un bref aperçu de l'état de l'art de l'asservissement visuel. Nous avons présenté différents types de classifications de l'AV en fonction de la position de la caméra, du contrôleur utilisé (celui du constructeur ou celui conçu au laboratoire) et enfin en fonction du type de la grandeur à asservir. Néanmoins une autre classification, aussi importante, selon la nature de tâche à réaliser peut être envisagée. En effet selon que l'objet cible soit statique ou animé d'un mouvement, la tâche à réaliser, est soit de positionnement ou de poursuite. Nous parlerons alors d'asservissement visuel de *positionnement* ou d'asservissement visuel de *poursuite*. Dans ce qui suit, nous allons nous intéresser au dernier cas, à savoir l'application de l'asservissement visuel pour la poursuite et le suivi de cible manoeuvrantes ou fuyantes.

Chapitre II

Estimation Robuste aux Brusques Ruptures de Mouvements

II.1 Introduction

Le filtre Kalman a été appliqué à une large variété de problèmes pratiques. Dans quelques cas, le système dynamique étudié est linéaire et peut être modélisé tout à fait correctement. Pour de tels problèmes le filtre de Kalman s'exécute extrêmement bien. Cependant, il existe beaucoup d'applications pour lesquelles ces filtres standard sont inadéquats et on exige des filtres adaptatifs, à titre d'exemple les systèmes présentant des changements brusques de modèles [12].

Dans ce chapitre, nous allons proposer une solution au problème de la poursuite d'une cible manoeuvrante, en d'autres termes une cible qui suit une trajectoire donnée durant un certain temps, ensuite elle décide d'opérer un changement au niveau de cette dernière, ce changement est considéré comme une rupture au niveau du modèle de mouvement considéré. Le problème posé, est comment maintenir un bon suivi de la cible malgré cette rupture brusque de modèle, pour cela il faut envisager un filtre capable de s'adapter rapidement à ce changement.

Avant de décrire l'approche proposée pour résoudre ce problème, nous allons émettre l'hypothèse suivante: nous supposons que les changements abrupts du système peuvent avoir lieu mais qu'ils se produisent *rarement*, c'est à dire que le modèle de base est correct à l'exception d'anomalies sporadiques. La philosophie de cette approche est comme suit :

Nous rendons effectif un filtre de Kalman basé sur la supposition qu'il n'existe aucun changement abrupt dans le système, et on conçoit un système secondaire qui dirige des résidus de la mesure, pour déterminer si un changement s'est produit et ajuster le filtre en conséquence. Le raisonnement justifiant cette structure est que, puisque les changements se produisent relativement rarement, on ne souhaite pas dégrader la performance de notre filtre sous conditions normales en exigeant que notre estimateur de l'état soit sensible directement aux changements du système.

II.2 Systèmes stochastiques avec des sauts inconnus

Les équations de modèle d'état et de mesure du filtre de Kalman (tenant compte d'un hypothétique saut au niveau du vecteur d'état à l'instant θ) s'écrivent de manière générale sous la forme suivante :

$$x(k+1) = \Phi x(k) + v(k) + \delta_{\theta, k+1} \nu \quad (\text{II.1})$$

$$z(k+1) = Hx(k+1) + w(k) \quad (\text{II.2})$$

où :

- $x(k)$ vecteur d'état;
- $z(k)$ vecteur de mesure;
- Φ matrice de transition d'état;
- H matrice d'observation;
- v bruit d'état, supposé gaussien centré de matrice de covariance Q ;
- $\delta_{i,j}$ est le symbole de Kronecker ;
- ν est le saut hypothétique ;
- w est le bruit de mesure, supposé également gaussien centré de matrice de covariance R ;

Rappelons que les équations du filtre de Kalman sont données par :

- la prédiction du vecteur d'état :

$$x(k+1/k) = \Phi x(k/k) \quad (\text{II.3})$$

- la matrice de covariance de l'erreur :

$$P(k+1/k) = \Phi P(k/k) \Phi^T + Q \quad (\text{II.4})$$

- l'estimation du vecteur d'état :

$$x(k+1/k+1) = x(k+1/k) + K(k+1)\gamma(k+1) \quad (\text{II.5})$$

- la matrice de covariance de l'erreur d'estimation :

$$P(k+1/k+1) = (I - K(k+1)H)P(k+1/k) \quad (\text{II.6})$$

où :

- ✓ $\gamma(k+1)$ est l'innovation entre la mesure et la prédiction :

$$\gamma(k+1) = z(k+1) - Hx(k+1/k) \quad (\text{II.7})$$

- ✓ $K(k+1)$ est le gain du filtre de Kalman :

$$K(k+1) = P(k+1/k)H^T V^{-1}(k+1) \quad (\text{II.8})$$

- ✓ $V(k+1)$ est la variance de l'innovation $\gamma(k+1)$:

$$V(k+1) = HP(k+1/k)H^T + R \quad (\text{II.9})$$

II.2.1 Formulation de l'approche dans le cas linéaire

Considérons le filtre de Kalman décrit précédemment, le problème posé est de mettre en œuvre un algorithme capable de *détecter*, d'*estimer* et de *compenser* des changements brusques dans le vecteur d'état du système considéré.

Nous cherchons à détecter tout saut se produisant éventuellement à un instant inconnu. Afin d'éviter une banque de données croissante et trop importante, Nous considérons à l'itération k , une fenêtre ($k - M < \theta \leq k$) où M est la largeur choisie de la fenêtre, et nous testons l'hypothèse q'un saut s'est produit pour tout instant θ compris dans l'intervalle de cette fenêtre. La taille de cette fenêtre M doit cependant être choisie suffisamment grande pour contrer l'aspect fortement bruité du signal à estimer [31].

Quand un saut se produit à l'instant θ , il influence la valeur de l'innovation et donc l'estimée de l'état. L'innovation $\gamma(k)$ peut être exprimée alors comme la somme de deux termes :

$$\gamma(k) = \gamma(k)_{nj} + G(k, \theta)\nu \quad (\text{II.10})$$

où :

- ✓ $\gamma(k)_{nj}$ représente l'innovation s'il ne se produit pas un saut ;
- ✓ $G(k, \theta)\nu$ est l'effet du saut ν qui se produit à l'itération θ , sur la valeur de l'innovation $\gamma(k)$ mesurée à l'itération k .

Le vecteur d'état s'écrit de façon similaire comme une somme de deux termes :

$$x(k/k) = x(k/k)_{nj} + F(k, \theta)\nu \quad (\text{II.11})$$

où :

- ✓ $x(k/k)_{nj}$ est l'estimée du vecteur d'état s'il ne se produit pas de saut ;
- ✓ $F(k, \theta)\nu$ est l'effet d'un saut qui se produit à l'itération θ , sur la valeur de l'estimée du vecteur d'état à l'itération k .

La détection et l'estimation d'un saut sont essentiellement basées sur la valeur des matrices $G(k; \theta)$ et $F(k; \theta)$. Nous allons à présent les déterminer explicitement pour les différentes valeurs possibles de θ .

- Cas $\theta > k$: pour ce cas on a évidemment :

$$G(k; \theta) = 0$$

- Cas $\theta = k$: on s'intéresse maintenant à calculer $G(\theta; \theta)$ et $F(k; \theta)$. Si l'on suppose l'existence d'un saut ν à l'instant θ , le vecteur d'état et la mesure peuvent s'écrire :

$$x(\theta) = x(\theta)_{nj} + \nu \quad (\text{II.12})$$

$$z(\theta) = z(\theta)_{nj} + H\nu$$

où $x(\theta)_{nj}$ et $z(\theta)_{nj}$ représentent respectivement la valeur du vecteur d'état et de la mesure en l'absence de saut. L'équation précédente et la définition de l'innovation permettent d'écrire alors :

$$\gamma(\theta) = \gamma(\theta)_{nj} + H\nu \quad (\text{II.13})$$

Par identification de cette dernière expression avec la définition de $G(k; \theta)$, donnée par (II.10), on obtient :

$$G(\theta; \theta) = H$$

Par ailleurs, l'équation d'estimation du vecteur d'état (II.5) et l'expression de l'innovation (II.13) $\gamma(\theta)$ nous donnent :

$$x(\theta/\theta) = x(\theta/\theta)_{nj} + K(\theta)H\nu \quad (\text{II.14})$$

Par identification de (II.11) avec la définition de $F(k;\theta)$ on en déduit :

$$F(\theta;\theta) = K(\theta)H$$

- Cas $\theta < k$: nous voulons déterminer à présent pour tout θ compris entre $k-M$ et k , la valeur de $G(k,\theta)$ et $F(k,\theta)$. Il est possible de calculer ces termes récursivement en fonction de $G(k-1;\theta)$ et $F(k-1;\theta)$, ces valeurs étant obtenues à l'itération précédente.

En effet, si l'on suppose l'existence du saut à l'instant θ , le vecteur d'état peut s'écrire sous la forme :

$$x(k) = x(k)_{nj} + \Phi(k-\theta)\nu \quad (\text{II.15})$$

En appliquant l'équation de mesure (II.2) à l'équation précédente, nous obtenons :

$$z(k) = z(k)_{nj} + HK(k-\theta)\nu \quad (\text{II.16})$$

Par ailleurs, en multipliant l'équation de prédiction du vecteur d'état (II.5) par H , nous aurons :

$$z(k/k-1) = Hx(k/k-1) = H\Phi x(k-1/k-1) \quad (\text{II.17})$$

En combinant cette dernière avec l'équation donnant le vecteur d'état $x(k/k)$, nous obtenons :

$$z(k/k-1) = z(k/k-1)_{nj} + H\Phi F(k-1;\theta)\nu \quad (\text{II.18})$$

Nous déduisons, en considérant les expressions (II.16) et (II.18), la valeur de l'innovation $\gamma(k)$:

$$\gamma(k) = \gamma(k)_{nj} + (H\Phi(k-\theta) - H\Phi F(k-1;\theta))\nu \quad (\text{II.19})$$

Par identification avec (II.10), on peut déduire :

$$G(k,\theta) = H\Phi(k-\theta) - H\Phi F(k-1;\theta) \quad (\text{II.20})$$

Pour calculer $F(k,\theta)$, nous combinons l'équation de prédiction du vecteur d'état avec l'équation (II.11), ce qui donne :

$$x(k/k-1) = x(k/k-1)_{nj} + \Phi F(k-1;\theta)\nu \quad (\text{II.21})$$

En utilisant les expressions (II.21) et (II.10), l'équation d'estimation du vecteur d'état s'écrit comme suit :

$$x(k/k) = x(k/k)_{nj} + (\Phi F(k-1;\theta) + K(k)G(k;\theta))\nu \quad (\text{II.22})$$

par identification avec (II.11), nous obtenons finalement :

$$F(k,\theta) = \Phi F(k-1;\theta) + K(k)G(k;\theta) \quad (\text{II.23})$$

Nous savons donc calculer de façon récurrente, à chaque itération k pour tout instant θ compris entre $k-M$ et k , les quantités $G(k;\theta)$ et $F(k;\theta)$. Celles-ci sont en effet nécessaires pour calculer le rapport de vraisemblance permettant la détection d'un hypothétique saut sur le vecteur d'état.

Nous considérons deux hypothèses: la première est qu'aucun saut ne s'est produit, et la deuxième suppose qu'un saut d'amplitude $\hat{\nu}(k)$ s'est

produit à l'itération θ . Etant donné les innovations calculées $\gamma(k-M+1), \dots, \gamma(k)$, à chaque hypothèse correspond une probabilité. $\hat{\nu}(k)$ est déterminée de façon à maximiser la probabilité qu'un saut s'est produit. Il représente l'amplitude du saut la plus vraisemblable à l'itération k pour chaque θ fixé si l'on considère qu'un saut s'est produit. La détection d'un saut à l'instant θ est basée sur le *rapport de vraisemblance* $l(k; \theta)$, plus connu sous le nom anglo-saxon de "Generalized Likelihood Ratio: GLR", donné par la formule suivante :

$$l(k; \theta) = 2 \log \frac{L(\gamma(k-M+1), \dots, \gamma(k) | H_1, \nu = \hat{\nu}(k))}{L(\gamma(k-M+1), \dots, \gamma(k) | H_0)} \quad (\text{II.24})$$

où :

- $L(\gamma/H)$ représente la fonction de probabilité telle que γ vérifie l'hypothèse H ;
- $\hat{\nu}(k)$ est défini par :

$$\hat{\nu}(k) = \arg \max(\gamma(k-M-1), \dots, \gamma(k) | H_1) \quad (\text{II.25})$$

- H_0 et H_1 sont respectivement les hypothèses qu'aucun saut ne s'est produit et qu'un saut d'amplitude $\hat{\nu}(k)$ s'est produit à l'itération θ .

Après développement, ce rapport de vraisemblance peut s'écrire en fonction de $G(k; \theta)$. En effet, nous avons :

$$l(k; \theta) = D^T(k; \theta) C^{-1}(k; \theta) D(k; \theta) \quad (\text{II.26})$$

avec :

$$C(k; \theta) = \sum_{j=\theta}^k G^T(j; \theta) V^{-1}(j) G(j; \theta) \quad (\text{II.27})$$

et :

$$D(k; \theta) = \sum_{j=\theta}^k G^T(j; \theta) V^{-1}(j) \gamma(j) \quad (\text{II.28})$$

Remarquons que les quantités $C(k; \theta)$ et $D(k; \theta)$ ne dépendent pas directement des valeurs $F(j; \theta)$ mais seulement des $G(j; \theta)$. Cependant $G(j; \theta)$ dépend de $F(j; \theta)$, ce qui nécessite son calcul. Signalons aussi que la valeur de F entre dans le calcul des équations de mise à jour de l'estimée et de la variance sur l'erreur d'estimation correspondante.

Comme le montrent les trois dernières équations (II.26), (II.27) et (II.28), $l(k; \theta)$ peut être considéré comme un test de corrélation entre les variations de l'innovation $\gamma(k)$ et la signature d'un saut.

Pour tout θ compris entre $k-M$ et k , nous calculons le rapport $l(k; \theta)$ et nous sélectionnons la valeur θ_m qui maximise la quantité $l(k; \theta)$ qui représente l'instant le plus probable où un saut s'est produit. Nous voyons bien que cette entité est à double maximisation : elle maximise la probabilité qu'il y'ait eu un saut en sélectionnant son amplitude (pour chaque instant probable), puis l'instant de sa production.

Nous appliquons par la suite la règle de décision suivante pour décider de la présence d'un saut ou pas à un instant θ_m donné (Test du GLR) :

$$\begin{array}{c} H_1 \\ l(k; \theta_m) > \varepsilon \\ < \varepsilon \\ H_0 \end{array} \quad (\text{II.29})$$

où ε est une valeur de seuil fixée .

Si un saut est détecté ($l(k; \theta_m) > \varepsilon$), l'estimée de l'instant $\hat{\theta}$ de sa production et l'estimée $\hat{v}(k; \hat{\theta})$ de sa réalisation sont alors données par :

$$\begin{cases} \hat{\theta} = \theta_m \\ \hat{v}(k; \hat{\theta}) = C^{-1}(k; \hat{\theta})D(k; \hat{\theta}) \end{cases} \quad (\text{II.30})$$

Cette estimée du saut est ensuite utilisée pour mettre à jour l'estimée du vecteur d'état dans le filtre de Kalman à travers l'équation de compensation suivante :

$$x(k/k)_{new} = x(k/k)_{old} + [\Phi(k - \hat{\theta}) - F(k; \hat{\theta})] \hat{v}(k; \hat{\theta}) \quad (\text{II.31})$$

Entre la production du saut et sa détection, il s'est passé $k - \hat{\theta}$ itérations. La mise à jour de l'estimée du vecteur d'état est donc réalisée par addition de l'effet d'un saut d'amplitude \hat{v} pendant $k - \hat{\theta}$ itérations suivant le modèle d'état (soit $\Phi(k - \hat{\theta})\hat{v}(k; \hat{\theta})$), et en retranchant la réponse du filtre de Kalman au saut avant sa détection. Rappelons que $F(k; \hat{\theta})\hat{v}$ représente la contribution d'un saut d'amplitude \hat{v} se produisant à l'instant $\hat{\theta}$, à l'estimée du vecteur d'état à l'instant k .

Finalement, nous signalons que pour prendre en compte l'erreur d'estimation du saut, il est nécessaire d'incrémenter la matrice de covariance de l'erreur de l'estimation.

L'équation de mise à jour est déduite de l'équation précédente, sachant que $C^{-1}(k; \hat{\theta})$ représente la matrice de covariance de l'erreur sur l'estimation du saut. On obtient alors:

$$P(k/k)_{new} = P(k/k)_{old} + [\Phi(k - \hat{\theta}) - F(k; \hat{\theta})]C^{-1}(k; \hat{\theta})[\Phi(k - \hat{\theta}) - F(k; \hat{\theta})]^T \quad (\text{II.32})$$

La réactualisation de $P(k/k)$ permet d'éviter les fausses alarmes à la suite de la détection d'un saut, car si l'on ne tient pas compte de l'erreur possible sur l'estimation du saut, on risque fortement de détecter un ou plusieurs faux sauts, ce qui entraînerait une instabilité dans l'estimation.

II.2.2 Calcul de la probabilité de détection

L'implémentation de l'algorithme du GLR [80], exige le choix du seuil de décision ϵ et la largeur de la fenêtre M . Ces entités sont choisies en faisant un compromis entre le temps de détection, la probabilité de fausse alarme P_F et la probabilité de détection $P_D(\nu, \theta)$ d'un saut d'amplitude ν à l'instant θ .

Ces probabilités sont données par :

$$\begin{aligned} P_F &= P_r(l = L / H_0) \\ P_D(\nu, \theta) &= P_r(l = L / H_1, \nu, \theta) \end{aligned} \quad (\text{II.33})$$

où :

- ✓ $P_r(l = L / H_0)$ est la probabilité de $l(k, \theta)$ conditionnée sur H_0
- ✓ $P_r(l = L / H_1, \nu, \theta)$ est la probabilité de $l(k, \theta)$ conditionnée sur H_1 et des valeurs particulières supposées de ν et θ .

On note $P_r(l = L / H_0)$ est une probabilité de densité de type χ_n^2 avec n degrés de liberté, et $P_r(l = L / H_1, \nu, \theta)$ la probabilité de densité χ_n^2 non centrée avec le paramètre de non centralité : $\delta^2 = \nu^T C(k, \theta) \nu$.

Les valeurs de P_F et P_D peuvent être calculées à partir de tableaux spéciaux [80]. Il en est de même pour la valeur de ϵ pour des valeurs spécifiées de P_F ou P_D .

II.3 Extension de l'approche au cas non linéaire

La majorité des problèmes traités dans la littérature, considère le cas de modèles et de systèmes linéaires, cependant qu'en est il des systèmes non linéaires. Dans ce paragraphe, nous nous proposons de donner une extension de la dite approche à cette catégorie de systèmes. Comme la majorité des systèmes de poursuite présentent une non linéarité au niveau du modèle de mesure seulement (le modèle d'état étant souvent linéaire); considérons le modèle du système donné par les équations suivantes :

$$\begin{aligned} x(k+1) &= \Phi(k)x(k) + v(k) \\ z(k) &= h(x(k), k) + w(k) \end{aligned} \quad (\text{II.34})$$

où :

- ✓ $x(k)$ vecteur d'état;
- ✓ $z(k)$ vecteur de mesure;
- ✓ Φ matrice de transition d'état;
- ✓ h matrice d'observation;
- ✓ v bruit d'état, supposé gaussien centré de matrice de covariance Q ;

- ✓ w est le bruit de mesure, supposé également gaussien centré de matrice de covariance R .

Comme le modèle de mesure est non linéaire, le filtre de Kalman standard doit être remplacé par le filtre de Kalman étendu, pour ce faire nous devons linéariser la matrice d'observation h . Nous appellerons H la matrice résultat de la linéarisation de h , elle se calcule par :

$$H(k) = \left. \frac{\partial h(x(k), k)}{\partial x(k)} \right|_{x(k)=\hat{x}(k/k-1)} . \quad (\text{II.35})$$

Les changements à apporter sur les équations de l'algorithme du GLR seront observés sur les grandeurs G et F dans les deux cas suivants :

- Cas $\theta = k$:

$$G(\theta; \theta) = \left. \frac{\partial h(x(\theta), \theta)}{\partial x(\theta)} \right|_{x(\theta)=\hat{x}(\theta/\theta-1)}$$

$$F(\theta, \theta) = K(\theta) \left. \frac{\partial h(x(\theta), \theta)}{\partial x(\theta)} \right|_{x(\theta)=\hat{x}(\theta/\theta-1)} . \quad (\text{II.36})$$

- Cas $\theta < k$:

$$G(k, \theta) = \left. \frac{\partial h(x(\theta), \theta)}{\partial x(\theta)} \right|_{x(\theta)=\hat{x}(\theta/\theta-1)} \cdot [\Phi(k - \theta) - \Phi F(k - 1; \theta)]$$

$$F(k, \theta) = \Phi F(k - 1; \theta) + K(k)G(k; \theta) . \quad (\text{II.37})$$

Nous pouvons alors, en utilisant ces équations, appliquer le test du GLR comme présenté pour le cas de modèles linéaires.

II.4 Modélisation des trajectoires [21]

Pour modéliser la trajectoire d'une cible, nous pouvons affirmer que quelque soit la complexité de cette dernière, elle pourra toujours être représentée par une succession de trajectoires élémentaire canoniques tels que des segments de droites, des arcs de cercles, des arcs elliptiques,.... A partir de la, nous pouvons dire que pour déterminer la trajectoire suivie par une cible donnée durant un temps \mathbf{t} , il suffit de déterminer les paramètres des différentes trajectoires canoniques suivies par la cible durant ce temps.

Dans notre cas, nous allons restreindre les trajectoires canoniques choisies au segment de droite et à l'arc de cercle.

II.4.1 Modèle d'une droite

Nous modéliserons une droite de la manière suivante:




Figure (II.1) : Modélisation d'une droite

Cette représentation permet de définir toute droite par ses coordonnées plucklériennes qui sont:

- la distance minimale d qui sépare la droite de l'origine des coordonnées;
- l'angle α que fait l'axe des abscisses avec la droite reliant l'origine à sa projection orthogonale sur la droite considérée.

D'autre part, nous représentons le mouvement sur une droite par les grandeurs suivantes :

- La distance parcourue S ;
- La vitesse de déplacement \dot{S} ;
- L'accélération \ddot{S} .

Cette représentation permet d'avoir un découplage entre le mouvement et la trajectoire suivie.

Le modèle d'état associé à un mouvement à vitesse constante sur une droite sera donc défini comme suit :

$$\dot{x} = Fx + v \quad (\text{II.38})$$

où :

v : Bruit d'état ;

$x^T = (S \quad \dot{S} \quad \alpha \quad d)$: Vecteur d'état

La matrice de transition F sera donc :

$$F = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

Le modèle de mesure sera :

$$Z = \begin{bmatrix} X \\ Y \end{bmatrix} = h(x) + w = \begin{bmatrix} S * \sin(\alpha) + d * \cos(\alpha) \\ -S * \cos(\alpha) + d * \sin(\alpha) \end{bmatrix} + w \quad (\text{II.39})$$

Avec:

w : Bruit de mesure ;

Nous remarquons que la matrice de mesure $h(x)$ est non-linéaire par rapport au vecteur d'état x . Une linéarisation est donc indispensable pour pouvoir implémenter un filtre de Kalman. Ceci est réalisé en considérant une petite variation dans l'état :

$$H_x = \begin{bmatrix} \frac{\partial X}{\partial S} & \frac{\partial X}{\partial \dot{S}} & \frac{\partial X}{\partial \alpha} & \frac{\partial X}{\partial d} \\ \frac{\partial Y}{\partial S} & \frac{\partial Y}{\partial \dot{S}} & \frac{\partial Y}{\partial \alpha} & \frac{\partial Y}{\partial d} \end{bmatrix}$$

Dans ce cas :

$$H_x = \begin{bmatrix} \sin(\alpha) & 0 & -d * \cos(\alpha) + S * \cos(\alpha) & \cos(\alpha) \\ -\cos(\alpha) & 0 & d * \cos(\alpha) - S * \sin(\alpha) & \sin(\alpha) \end{bmatrix} \quad (\text{II.40})$$

Si Nous considérons maintenant le cas d'un mouvement à accélération constante, la seule différence sera remarquée au niveau des matrices F et H_x .

Nous aurons un vecteur d'état : $x^T = (S \quad \dot{S} \quad \ddot{S} \quad \alpha \quad d)$

Par conséquent :

$$F = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

et :

$$H_x = \begin{bmatrix} \sin(\alpha) & 0 & 0 & -d * \sin(\alpha) + S * \cos(\alpha) & \cos(\alpha) \\ -\cos(\alpha) & 0 & 0 & d * \cos(\alpha) - S * \sin(\alpha) & \sin(\alpha) \end{bmatrix} \quad (\text{II.41})$$

II.4.2 Modèle d'un cercle

Comme pour le cas d'une droite, et pour réaliser un découplage entre le mouvement et la trajectoire, nous définirons un cercle comme suit :




Figure (II.2): Modélisation d'un cercle

Avec:

- R : rayon du cercle,
- $\{X_0 \ Y_0\}$: centre du cercle.

Le vecteur d'état associé à un mouvement à vitesse constante sur une trajectoire circulaire sera donc : $x^T = (S \ \dot{S} \ R \ X_0 \ Y_0)$

$$\text{L'équation d'état est : } \dot{x} = Fx + v \quad (\text{II.42})$$

La matrice de transition F sera :

$$F = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Le modèle de mesure s'écrira :

$$z = \begin{bmatrix} X \\ Y \end{bmatrix} = h(x) + w = \begin{bmatrix} X_0 + R * \cos(S/R) \\ Y_0 + R * \sin(S/R) \end{bmatrix} + w \quad (\text{II.43})$$

La matrice de mesure linéarisée se déduit par dérivation de $h(x)$

$$H_x = \begin{bmatrix} \frac{\partial X}{\partial S} & \frac{\partial X}{\partial \dot{S}} & \frac{\partial X}{\partial \ddot{S}} & \frac{\partial X}{\partial R} & \frac{\partial X}{\partial X_0} & \frac{\partial X}{\partial Y_0} \\ \frac{\partial Y}{\partial S} & \frac{\partial Y}{\partial \dot{S}} & \frac{\partial Y}{\partial \ddot{S}} & \frac{\partial Y}{\partial R} & \frac{\partial Y}{\partial X_0} & \frac{\partial Y}{\partial Y_0} \\ \frac{\partial S}{\partial S} & \frac{\partial S}{\partial \dot{S}} & \frac{\partial S}{\partial \ddot{S}} & \frac{\partial S}{\partial R} & \frac{\partial S}{\partial X_0} & \frac{\partial S}{\partial Y_0} \end{bmatrix}$$

Nous aurons alors :

$$H_x = \begin{bmatrix} -\sin \frac{S}{R} & 0 & \cos \frac{S}{R} + \frac{S}{R} \sin \frac{S}{R} & 1 & 0 \\ \cos \frac{S}{R} & 0 & \sin \frac{S}{R} - \frac{S}{R} \cos \frac{S}{R} & 0 & 1 \end{bmatrix} \quad (\text{II.44})$$

Pour un mouvement à accélération constante, le vecteur d'état sera :

$$x^T = (S \quad \dot{S} \quad \ddot{S} \quad R \quad X_0 \quad Y_0)$$

Par conséquent, les matrices H_x et F seront écrites de façon similaire aux cas précédents, ce qui donnera :

$$H_x = \begin{bmatrix} -\sin \frac{S}{R} & 0 & 0 & \cos \frac{S}{R} + \frac{S}{R} \sin \frac{S}{R} & 1 & 0 \\ \cos \frac{S}{R} & 0 & 0 & \sin \frac{S}{R} - \frac{S}{R} \cos \frac{S}{R} & 0 & 1 \end{bmatrix} \quad (\text{II.45})$$

et

$$F = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}.$$

II.5 Principe de la batterie de filtres

II.5.1 But

Un filtre de Kalman mal initialisé risque de diverger. Pour contourner ce problème, nous proposons de lancer, non pas un seul filtre, mais toute une batterie, chacun avec une initialisation différente. Théoriquement, le nombre de filtres à lancer simultanément dépend de la dimension du vecteur d'état et des contraintes physiques des variables d'état considérées. Le nombre des filtres à lancer par rapport à chaque variable d'état est fonction de la discrétisation de l'intervalle de variation de la variable considérée.

Une fois lancés, il y aura des filtres qui convergeront (ceux qui sont bien initialisés) comme il y'en a d'autres qui divergeront (ceux qui sont mal initialisés). Ces derniers seront tous simplement arrêtés.

Comme le calcul est itératif, à chaque itération les filtres lancés seront pondérés, et nous considèrerons un critère d'arrêt permettant d'arrêter les filtres divergents [79].

II.5.2 Principe de la méthode

Nous considérons que chaque variable d'état est comprise entre deux valeurs limites (contraintes physiques). Pour pouvoir lancer une batterie de filtres initialisés différemment, nous devons tout d'abord discrétiser cet intervalle de variation de la variable d'une façon adéquate. Plusieurs méthodes peuvent être imaginées. Nous pouvons penser, par exemple, à une discrétisation obéissant à une loi uniforme ou à une loi gaussienne.

Dans ce qui va suivre, nous considèrerons un problème de lancement d'une batterie de filtres où la variable d'état prise en compte sera la *vitesse*.

Nous supposons que la cible à une vitesse qui varie dans l'intervalle $[V_{Min}, V_{Max}]$. Cette hypothèse est réaliste car la vitesse d'un mobile ne peut pas atteindre des valeurs que les contraintes de fonctionnement ne tolèrent pas.

La méthode utilisée dans notre cas est décrite comme suit :

$$\text{Soit un pas } p_0 \text{ tel que : } p_0 = \frac{V_{Max} - V_{Min}}{\sum_{i=1}^{N_f} i} \quad (\text{II.46})$$

avec : N_f le nombre des filtres à lancer ;

$$\text{Comme, en général, } V_{Min} = 0 \text{ alors } p_0 = \frac{V_{Max}}{\sum_{i=1}^{N_f} i}$$

Nous prendrons alors des intervalles de la forme $[\alpha(j-1)p_0 \quad \alpha(j)p_0]$ avec :

$$\begin{cases} 1 < j < N_f \\ \alpha(j) = \sum_{i=0}^j i \end{cases} \quad (\text{II.47})$$

Finalement, les initialisations prises seront les centres des intervalles décrits, d'où l'initialisation en vitesse du filtre de la cellule $[\alpha(j-1)p_0 \quad \alpha(j)p_0]$ sera :

$$V_{j0} = \frac{\alpha(j)p_0 + \alpha(j-1)p_0}{2} \quad (\text{II.48})$$

La pondération des filtres est calculée dans notre cas par la relation :

$$W_k = \left(\frac{1}{\sqrt{2\pi}} \right) \exp \left(-\sqrt{(X(k) - \hat{X}(k))^2 + (Y(k) - \hat{Y}(k))^2} \right) \quad (\text{II.49})$$

Avec :

$\begin{bmatrix} X(k) \\ Y(k) \end{bmatrix}$: Mesure à l'instant k ;

$\begin{bmatrix} \hat{X}(k) \\ \hat{Y}(k) \end{bmatrix}$: L'estimation de la mesure à l'instant k .

Il est clair que les poids affectés aux filtres à l'itération k sont fonctions de la norme de la différence entre la valeur mesurée et la valeur estimée. Plus cette norme est grande, plus le poids du filtre sera petit. Par conséquent, pour décider de mettre un filtre à l'arrêt, il faut que la valeur de son poids soit inférieure à une certaine valeur limite fixée préalablement.

Dans notre cas, la pondération est prise comme une règle de décision qui est : Mettre le filtre hors fonctionnement si le filtre ne satisfait pas les conditions de convergence caractérisées par $W_k > \beta$ (seuil préalablement établi).

II.6 Simulation et commentaires

II.6.1 Filtrage de Kalman sans test de GLR

II.6.1.1 Cas d'un mouvement rectiligne à vitesse constante

Nous nous proposons de poursuivre un mobile se déplaçant le long d'une trajectoire rectiligne de paramètres inconnus à une vitesse constante inconnue. Le problème consiste à déterminer toutes ces inconnues pour assurer la poursuite du mobile. Les coordonnées x et y de sa position sont supposées acquises par le biais d'une caméra.

Dans l'implémentation de ce filtre les données visuelles (coordonnées cartésiennes de la cible) sont remplacées par des données générées par ordinateur auxquelles nous ajoutons un bruit blanc gaussien.

Nous considérons qu'au départ rien n'est connu. Par défaut nous initialisons le vecteur d'état par la valeur neutre, autrement dit, $x_0^T = (0 \ 0 \ 0 \ 0)$.

La matrice de covariance initiale est de la forme :

$$P_0 = \begin{bmatrix} \sigma^2 & 0 & 0 & 0 \\ 0 & \sigma^2 & 0 & 0 \\ 0 & 0 & \sigma^2 & 0 \\ 0 & 0 & 0 & \sigma^2 \end{bmatrix},$$

On note que le terme $P_0(i, j)$ pour $i \neq j$ représente l'inter-corrélation entre la variable d'état d'ordre i et la variable d'ordre j . Nous supposerons que toutes les variables d'état sont indépendantes les unes des autres, ce qui nous permet d'écrire $\forall i \neq j, P_0(i, j) = 0$. Il est à noter aussi que σ^2 est prise grande, façon de dire que les valeurs initiales sont loin des conditions réelles de la cible.

Nous prendrons (par exemple):

$$P_0 = \begin{bmatrix} 5.10^3 & 0 & 0 & 0 \\ 0 & 5.10^3 & 0 & 0 \\ 0 & 0 & 5.10^3 & 0 \\ 0 & 0 & 0 & 5.10^3 \end{bmatrix}$$

L'exemple suivant consiste à estimer le mouvement d'une cible sur une droite dont les paramètres sont : $d=20$, $\alpha = 45^\circ$ et la vitesse du mouvement est $V = \dot{S} = 2\text{m/s}$.

Les résultats obtenus, après application du filtre de Kalman étendu sont illustrés par la figure suivante.

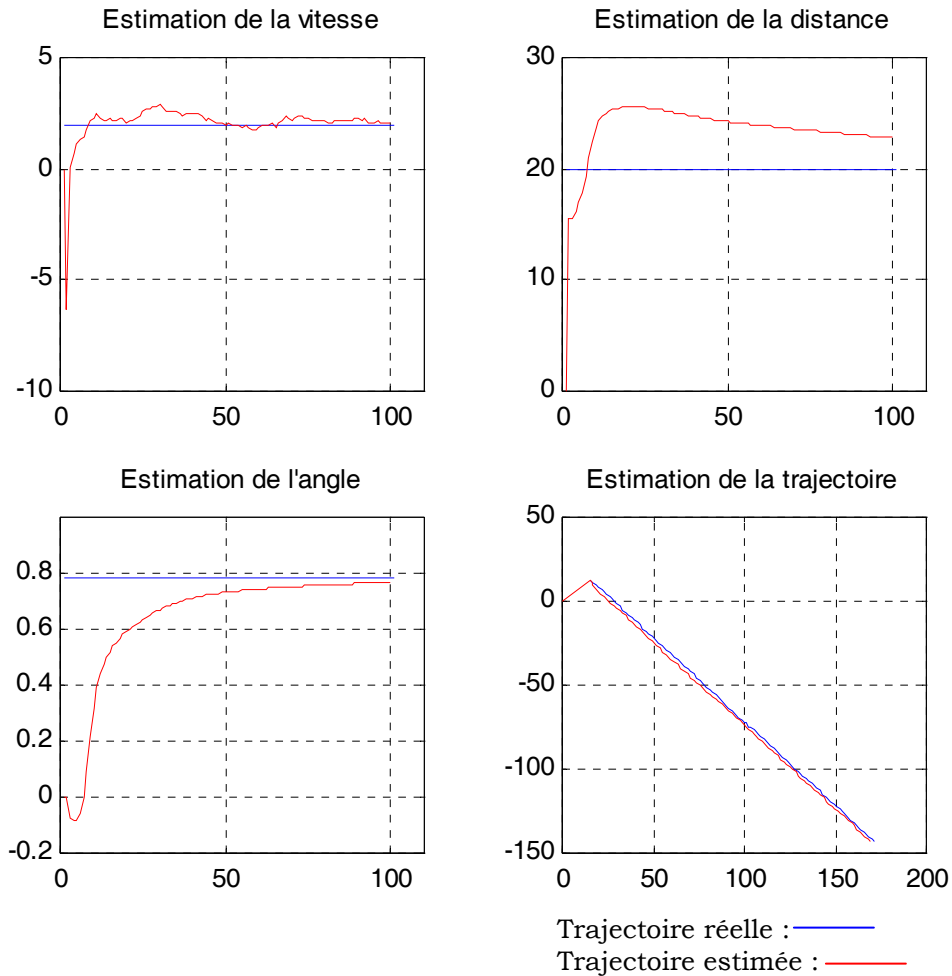


Figure (II.3) : Estimation des paramètres de mouvement rectiligne à vitesse constante

Cette figure montre une bonne estimation de la vitesse du mouvement de la cible ainsi que du paramètre " α " et une estimation acceptable du paramètre " d ".

II.6.1.2 Cas d'un mouvement rectiligne à accélération constante

Le problème posé dans ce paragraphe est identique au précédent, seule la nature du mouvement diffère. Le mouvement considéré est uniformément accéléré.

L'exemple suivant traite de la poursuite d'un mobile se déplaçant le long d'une droite caractérisée par les paramètres $d = 40; \alpha = 60^\circ$. Le mouvement considéré est uniformément accéléré où l'accélération est $\gamma = \ddot{S} = 0.5m/s^2$ et la vitesse initiale $V_0 = 0.5m/s$ (bien sûr, ces paramètres sont supposés inconnus au départ).

Pour cela, le vecteur d'état est initialisé par le vecteur :

$$x^T = (0 \ 0 \ 0 \ 0 \ 0)$$

Pour compenser cette initialisation (par défaut) nous surestimons la matrice de covariance P_0 :

$$P_0 = \begin{bmatrix} 5.10^3 & 0 & 0 & 0 & 0 \\ 0 & 5.10^3 & 0 & 0 & 0 \\ 0 & 0 & 5.10^3 & 0 & 0 \\ 0 & 0 & 0 & 5.10^3 & 0 \\ 0 & 0 & 0 & 0 & 5.10^3 \end{bmatrix}$$

Les résultats de simulation sont donnés par les figures suivantes :

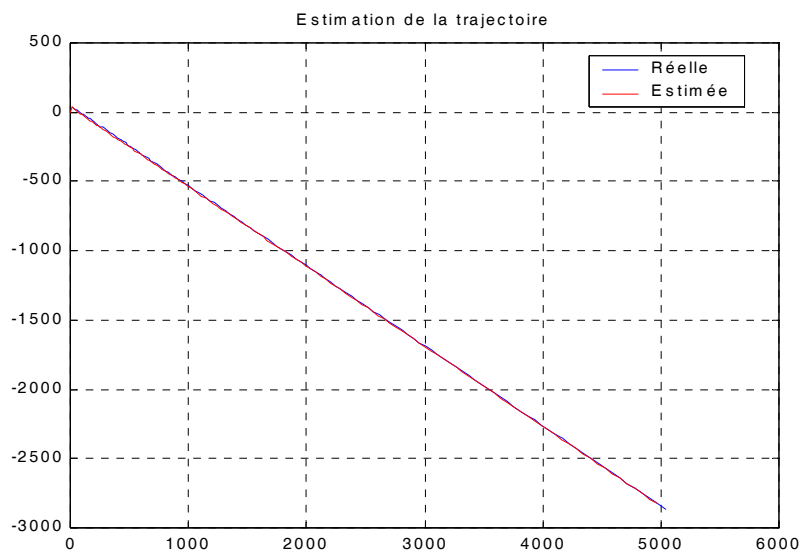


Figure (II.4) : Trajectoire estimée

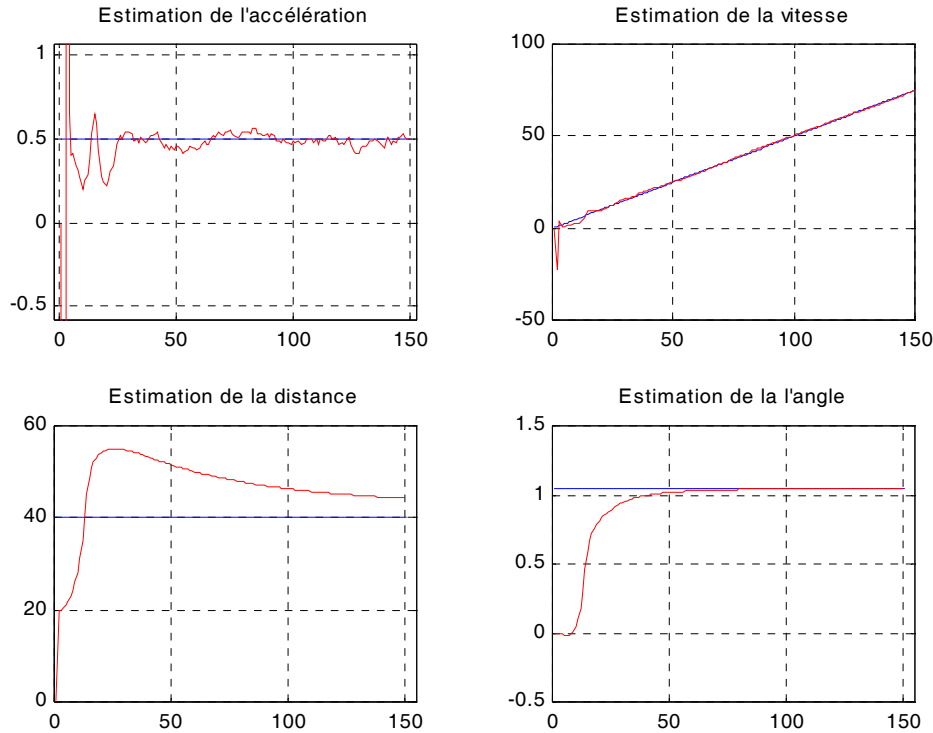


Figure (II.5) : Estimation des paramètres de mouvement rectiligne à accélération constante

Comme le montre les figures ci-dessus, nous avons une bonne convergence des paramètres de mouvement (vitesse, accélération) ainsi que ceux de la trajectoire (α et d).

II.6.1.3 Cas d'un mouvement circulaire à vitesse constante

Le problème posé est d'estimer le mouvement sur une trajectoire circulaire. Nous devons estimer les paramètres de la trajectoire qui sont les coordonnées du centre et le rayon, en plus des paramètres du mouvement représentés dans ce cas par la distance parcourue et la vitesse de déplacement. Nous supposons toujours que l'état initial est inconnu. Le vecteur d'état sera choisi comme suit :

$$x_0^T = (0 \quad 0 \quad 1 \quad 0 \quad 0)$$

Remarque : la troisième composante est prise non nulle pour éviter une division par zéro.

la matrice de covariance P_0 sera :

$$P_0 = \begin{bmatrix} 5.10^3 & 0 & 0 & 0 & 0 \\ 0 & 5.10^3 & 0 & 0 & 0 \\ 0 & 0 & 5.10^3 & 0 & 0 \\ 0 & 0 & 0 & 5.10^3 & 0 \\ 0 & 0 & 0 & 0 & 5.10^3 \end{bmatrix}.$$

La figure suivante illustre les résultats obtenus, pour la poursuite d'une cible ayant une vitesse de déplacement linéaire $V = 4m/s$, sur une trajectoire circulaire de rayon $R = 75m$ et de centre $(X_0, Y_0) = (2m, 6m)$.

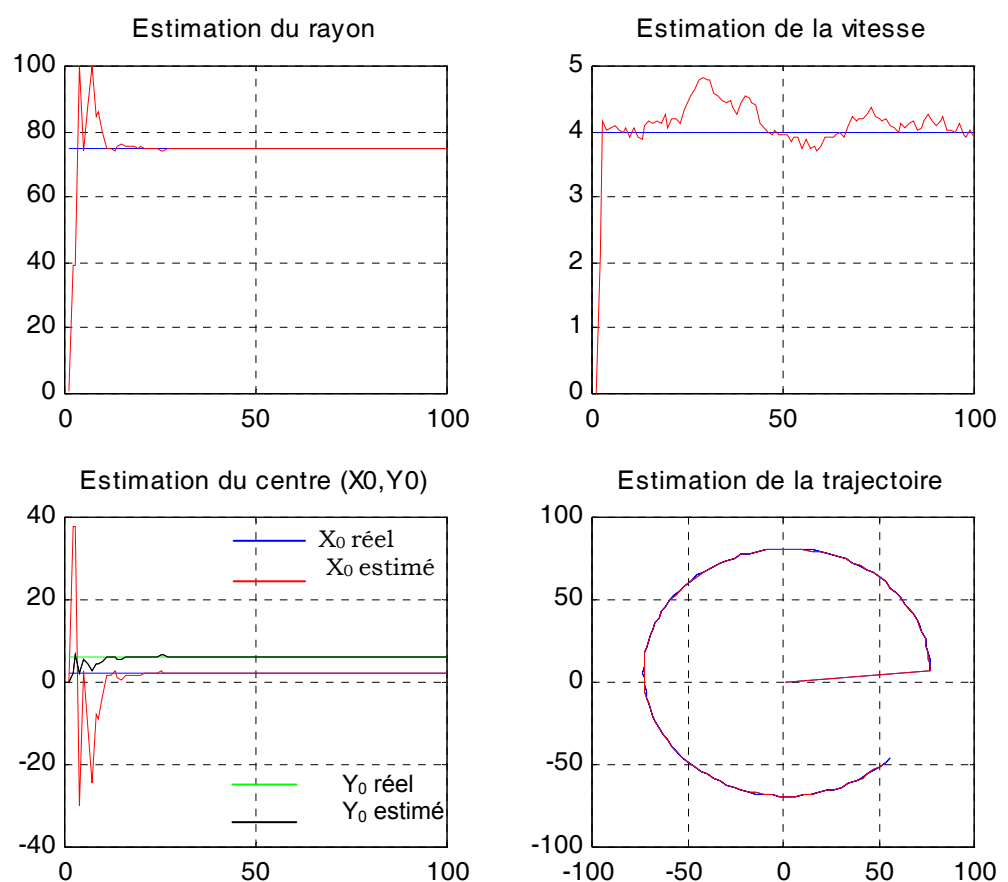


Figure (II.6) : Estimation des paramètres de mouvement circulaire à vitesse constante

La figure ci-dessus, montre un bon suivi de la trajectoire et une bonne estimation des paramètres de mouvement.

II.6.1.4 Cas d'un mouvement circulaire à accélération constante

Le problème posé est identique au précédent, cependant, cette fois-ci pour un mouvement à accélération constante. La figure ci-dessous, montre les résultats de simulations pour le cas suivant: $\gamma = \ddot{S} = 0.5m/s^2$ et une vitesse initiale $V_0 = 1m/s$. Le rayon et le centre du cercle sont: $R = 100m$; $X_0 = 10m$; $Y_0 = 5m$.

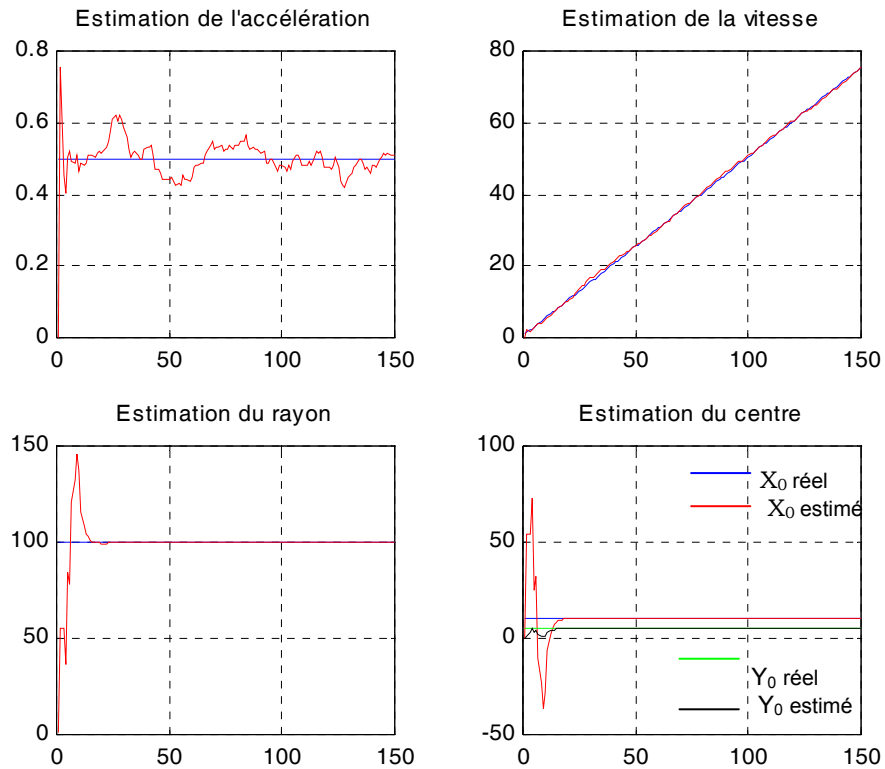


Figure (II.7) : Estimation des paramètres de mouvement circulaire à accélération constante

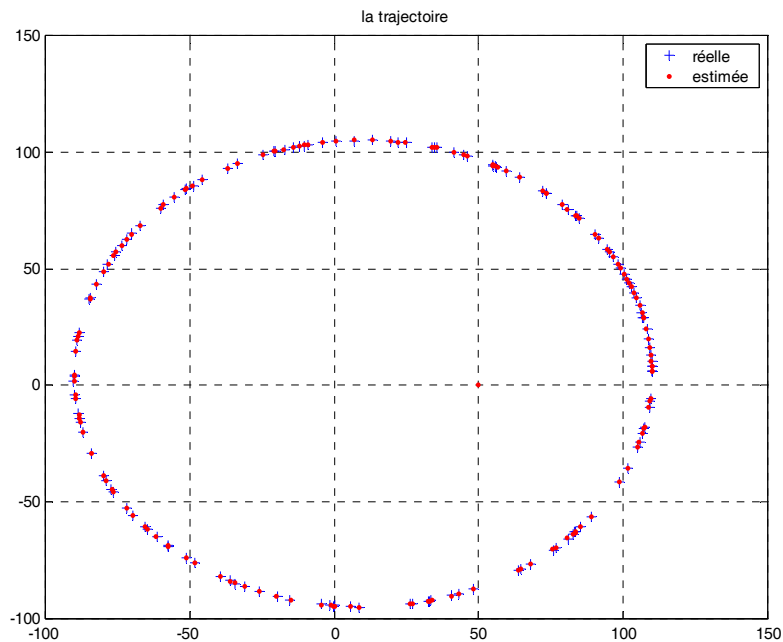


Figure (II.8) : Trajectoire estimée

D'après les figures ci-dessus, nous avons une bonne estimation des paramètres de mouvement et de trajectoire. En effet, comme le montre la figure II.8, la trajectoire estimée est confondue avec la trajectoire réelle.

II.6.2 Batterie de filtres

Pour illustrer l'intérêt de l'utilisation d'une batterie de filtres (assurer une bonne initialisation d'au moins un filtre, et augmenter la vitesse de convergence de l'algorithme de poursuite), nous allons considérer deux cas de figures.

II.6.2.1 cas d'un mouvement rectiligne à vitesse constante

Considérons le problème de poursuite d'une cible dont la vitesse maximale peut atteindre 10m/s.

Nous proposons de lancer une batterie de huit filtres ($N_f = 8$), avec les initialisations en vitesse suivantes : $V_{0_i} (m/s) = 0.14; 0.55; 1.25; 2.2; 3.5; 5; 6.6; 8.9$.

Le seuil d'arrêt est fixé (expérimentalement) à 10^{-5} .

La figure suivante illustre le comportement de ces filtres.

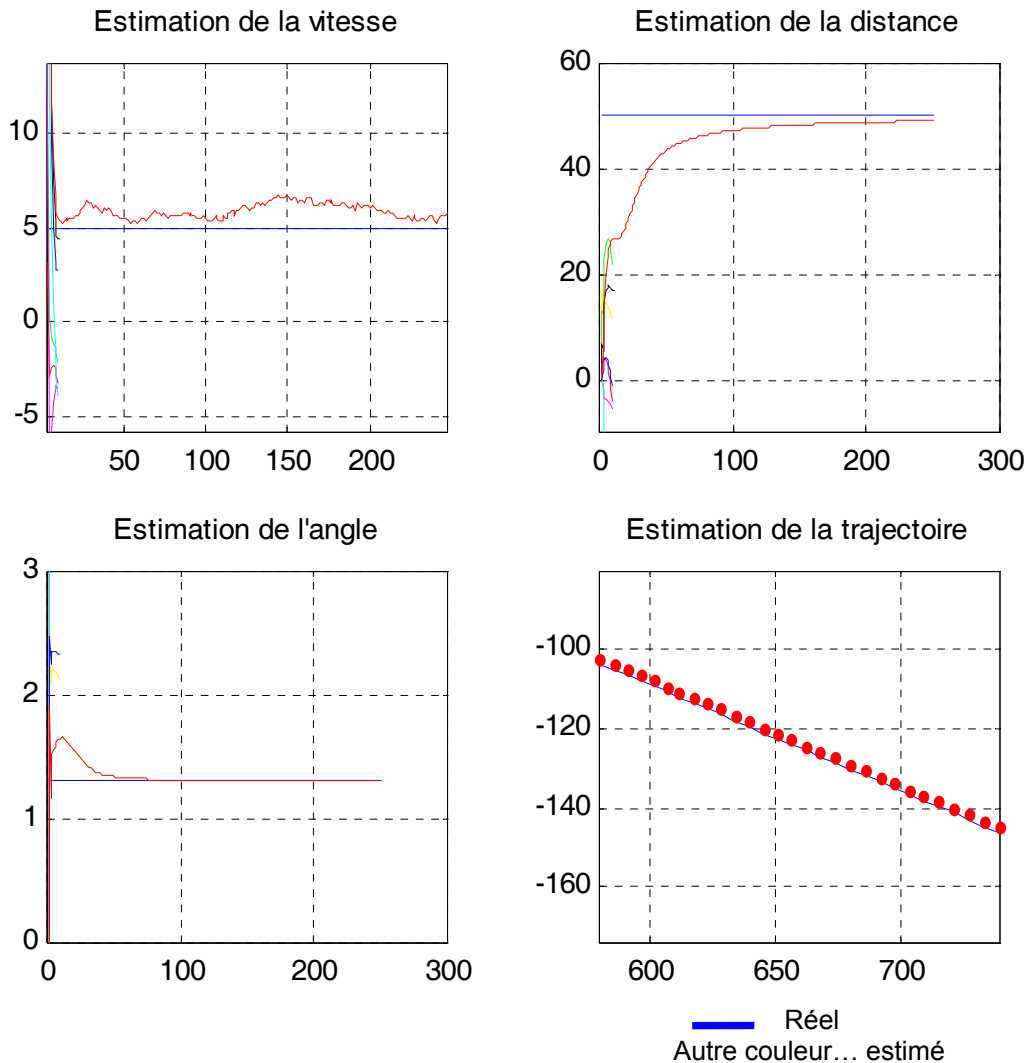


Figure (II.9) : Estimation de mouvement rectiligne à vitesse constante avec batterie de filtres

D'après la figure ci-dessus, nous remarquons que le filtre correctement initialisé a pu converger rapidement, par contre les autres sont arrêtés dès qu'ils dépassent le seuil préalablement fixé.

II.6.2.2 cas d'un mouvement circulaire à vitesse constante

Dans ce cas, nous considérons que la vitesse maximale peut atteindre 2m/s.

Afin d'assurer la poursuite de la cible, nous lançons une batterie de quatre filtres ($N_f = 4$), initialisés comme suit : $V_{01}=0.1\text{m/s}$; $V_{02}=0.4\text{m/s}$; $V_{03}=0.9\text{m/s}$; $V_{04}=1.6\text{m/s}$.

Le seuil d'arrêt des filtres divergents est fixé à 10^{-5} .

La figure suivante illustre le comportement de ces filtres.

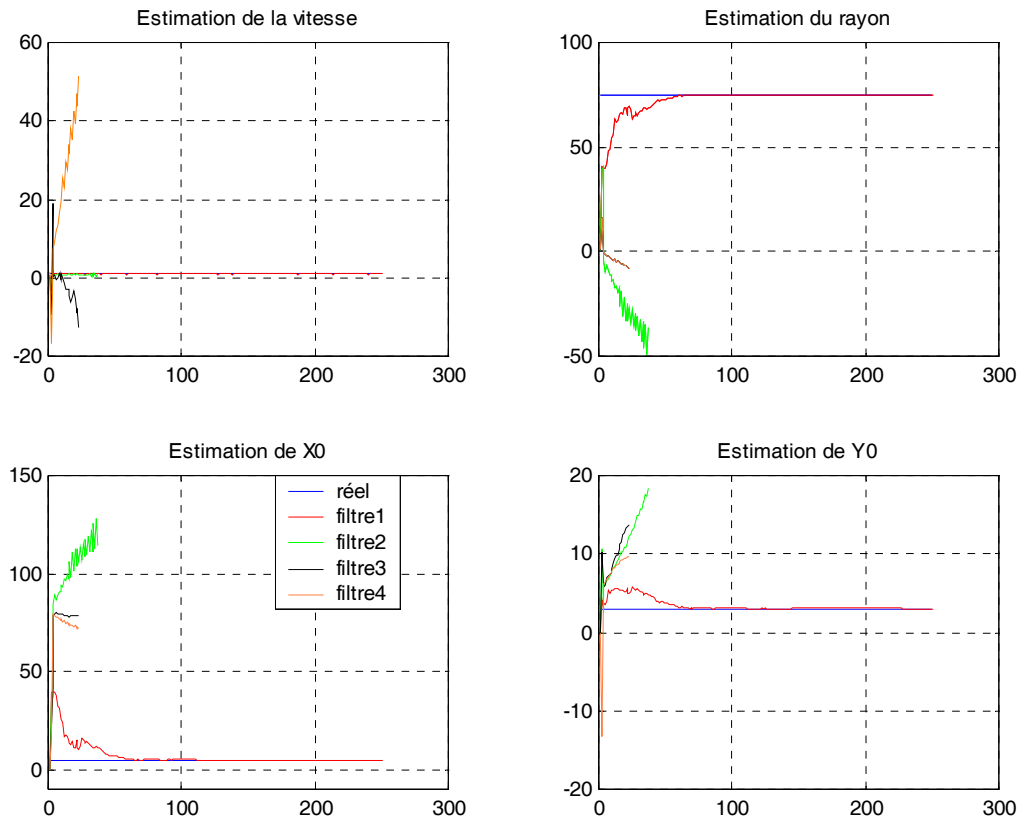


Figure (II.10) : Estimation de mouvement circulaire à vitesse constante avec batterie de filtres

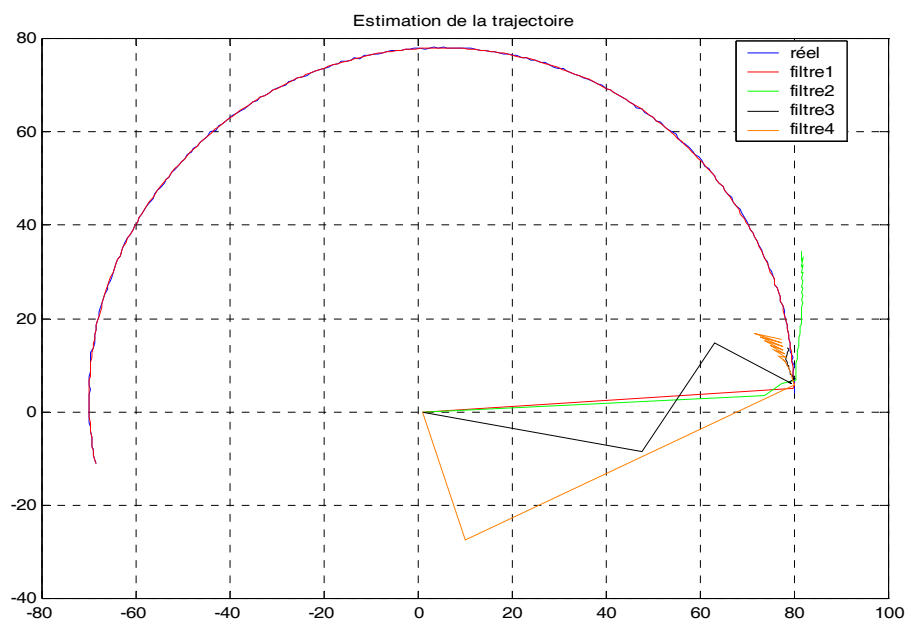


Figure (II.11) : Estimation de la trajectoire circulaire avec batterie de filtres

Comme dans le cas précédent, nous remarquons que le filtre correctement initialisé a pu converger rapidement, par contre les autres sont arrêtés dès qu'ils dépassent le seuil préalablement fixé. Nous pouvons également affirmer que sans cette batterie de filtres, rien ne pouvait nous garantir une bonne initialisation du filtre de poursuite et donc la convergence de notre filtre.

II.6.3 Filtre de Kalman avec test de GLR

Le problème que nous allons traiter concerne le cas de la poursuite d'une cible présentant des changements brusques et sporadiques au niveau des paramètres du mouvement, pour simplifier nous allons considérer que le saut survient uniquement au niveau du paramètre *vitesse*. Pour ce faire, nous allons comparer le comportement du filtre de Kalman seul face à une telle situation avec son comportement en s'aidant de l'algorithme du GLR.

II.6.3.1 Cas de sauts en vitesse sur une trajectoire rectiligne

Nous voulons estimer le mouvement d'une cible se déplaçant le long d'une trajectoire rectiligne. Cette cible effectue des manœuvres en changeant brusquement l'amplitude de la vitesse de déplacement (cas d'un avion de chasse voulant se libérer de la poursuite radar ennemi).

L'application du filtre de Kalman avec et sans test du GLR a donné les résultats représentés sur la figure suivante :

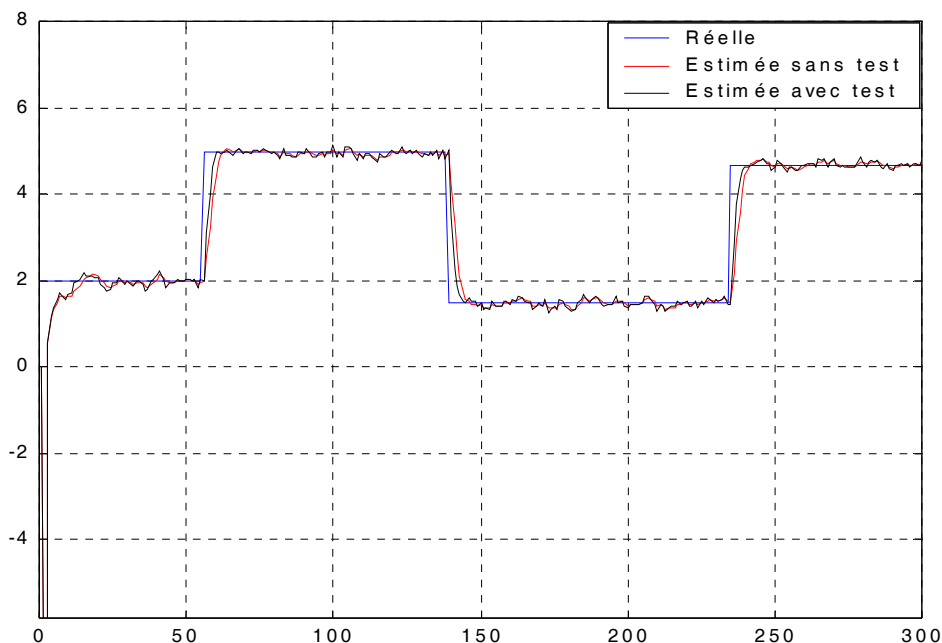


Figure (II.12) : Estimation de la vitesse : cas d'un mouvement rectiligne

La figure ci-dessus représente l'évolution dans le temps de la vitesse de la cible dont l'amplitude a changé brusquement à différents instants.

Nous remarquons que le filtre de Kalman sans test arrive à suivre l'évolution de la vitesse, ce malgré un certain retard au niveau de la convergence aux nouvelles valeurs de la vitesse. Cette convergence est due essentiellement à la *robustesse du modèle*.

C'est également le cas du filtre avec test du GLR. Même si nous remarquons que le filtre muni du test du GLR a convergé un peu plus vite que le filtre sans test.

II.6.3.2 Cas de sauts en accélération sur une trajectoire rectiligne

Dans cet exemple, la cible effectue des sauts brusques sur son accélération et par conséquent sa vitesse.

La figure suivante représente l'allure de la vitesse et de l'accélération estimée avec et sans test du GLR.

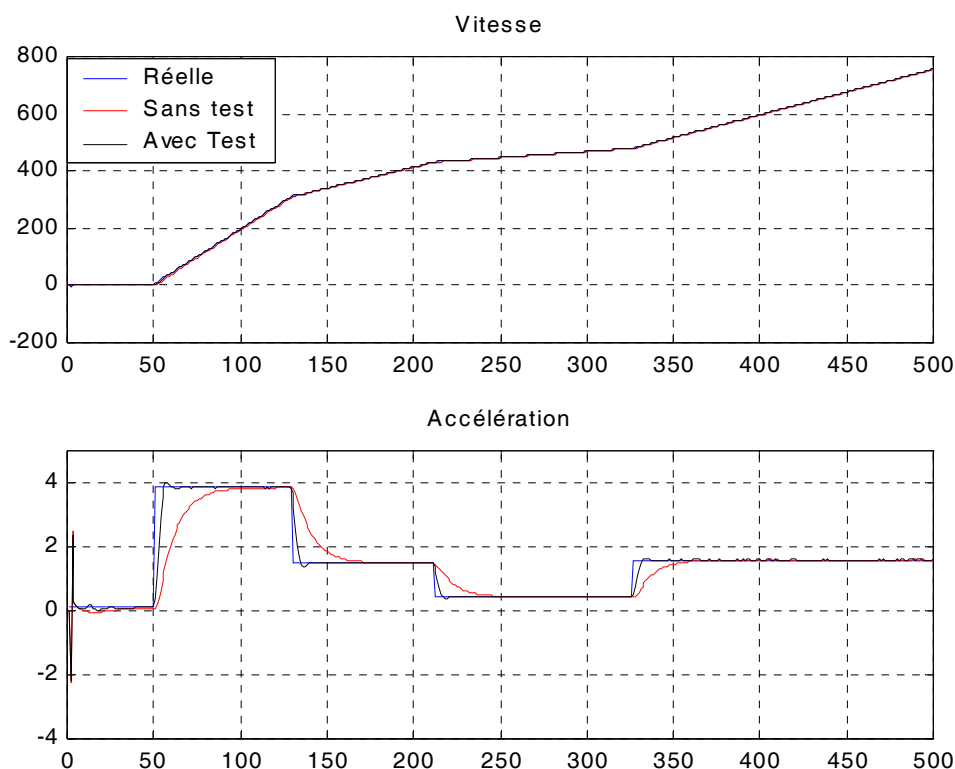


Figure (II.13) : Estimation de la vitesse et de l'accélération : cas d'un mouvement rectiligne

Comme l'indique si bien la figure ci-dessus, l'effet du test du GLR est nettement remarqué. En effet, ce test a permis au filtre de Kalman de converger nettement plus vite que le filtre sans le dit test.

II.6.3.3 Cas de sauts en vitesse sur une trajectoire circulaire

Nous voulons à présent tester le comportement du filtre de Kalman avec et sans test du GLR dans le cas où la cible effectue un mouvement circulaire avec une vitesse constante, nous supposons le cas de sauts sporadiques sur cette dernière.

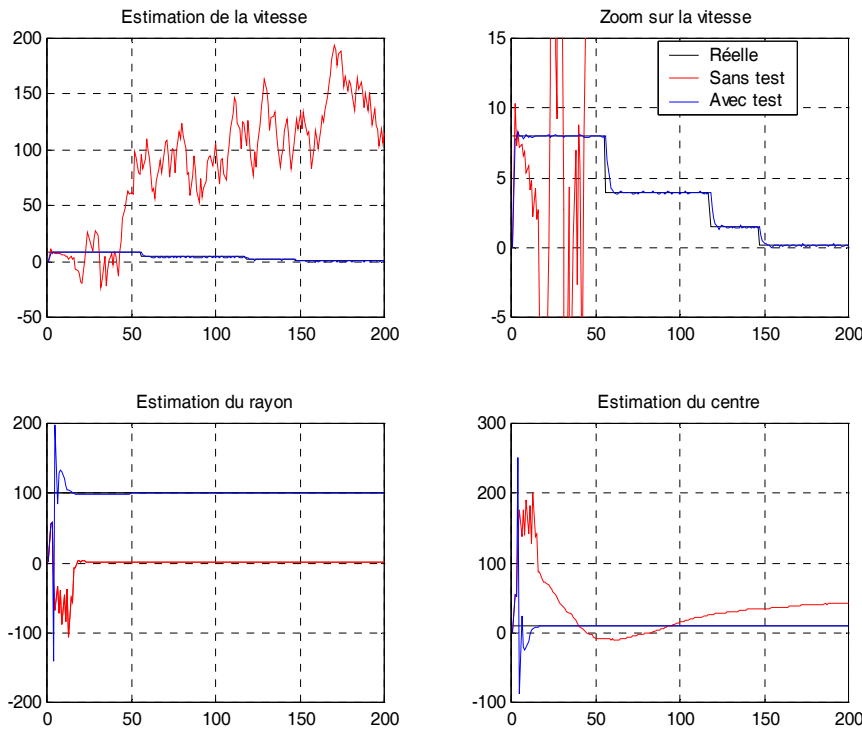


Figure (II.14) : Estimation des paramètres de mouvement sur une trajectoire circulaire avec saut en vitesse sans test du GLR

La figure ci-dessus montre que l'effet du saut est néfaste pour le filtre de poursuite, en effet ce dernier diverge complètement.

Par contre, comme le montre si bien la figure ci-dessous, la jonction du test du GLR au filtre de Kalman permet au filtre de rattraper et de corriger ses erreurs de prédiction et d'estimation et ainsi garantir un bon suivi de la cible malgré l'avènement sporadique des sauts en vitesse.

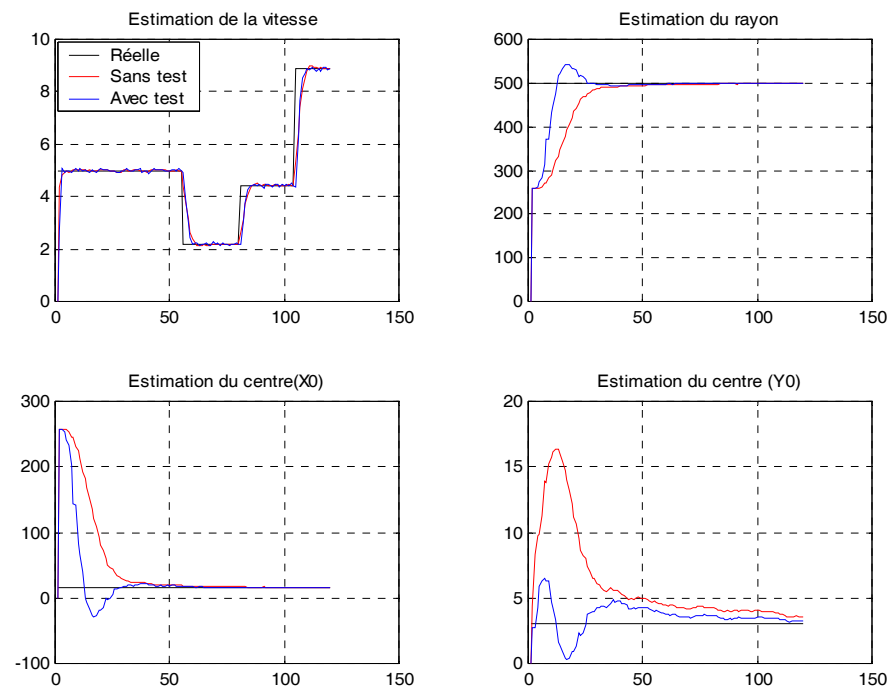


Figure (II.15) : Estimation des paramètres de mouvement sur une trajectoire circulaire avec saut en vitesse et avec test du GLR

II.6.3.4 Cas de sauts en accélération sur une trajectoire circulaire

Comme pour le cas des sauts en vitesse, le test du GLR a un rôle aussi bien correctif que compensatif. Les figures (II.17) et (II.18) montrent l'effet du test du GLR respectivement sur l'estimation des paramètres du mouvement et ceux de la trajectoire.

Les figures ci-dessous, mettent clairement en évidence la nécessité du test de GLR pour assurer un suivi d'une cible effectuant des manœuvres. Car, comme le montrent si bien ces figures, sans test du GLR, le filtre de poursuite diverge complètement, par contre avec ce dernier, le filtre de poursuite est capable d'estimer les instants des sauts et leurs amplitudes ainsi que la compensation des estimées ce qui entraîne, comme l'illustrent les figures ci-dessous, la convergence du filtre de poursuite.

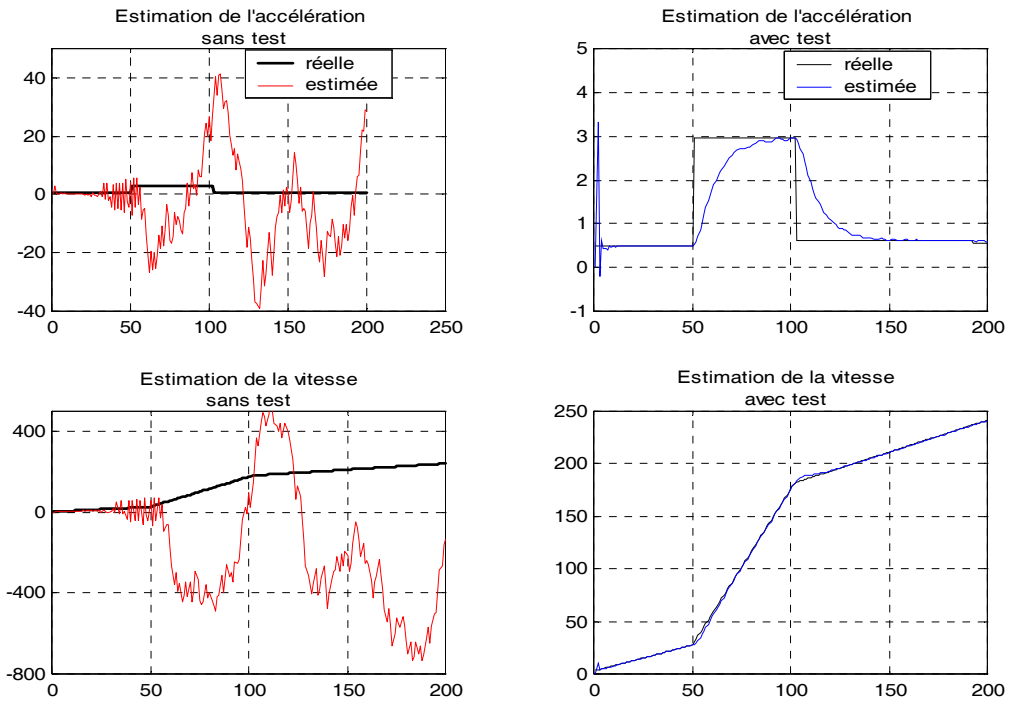


Figure (II.16) : Estimation des paramètres de mouvement avec sauts en accélération sur un cercle

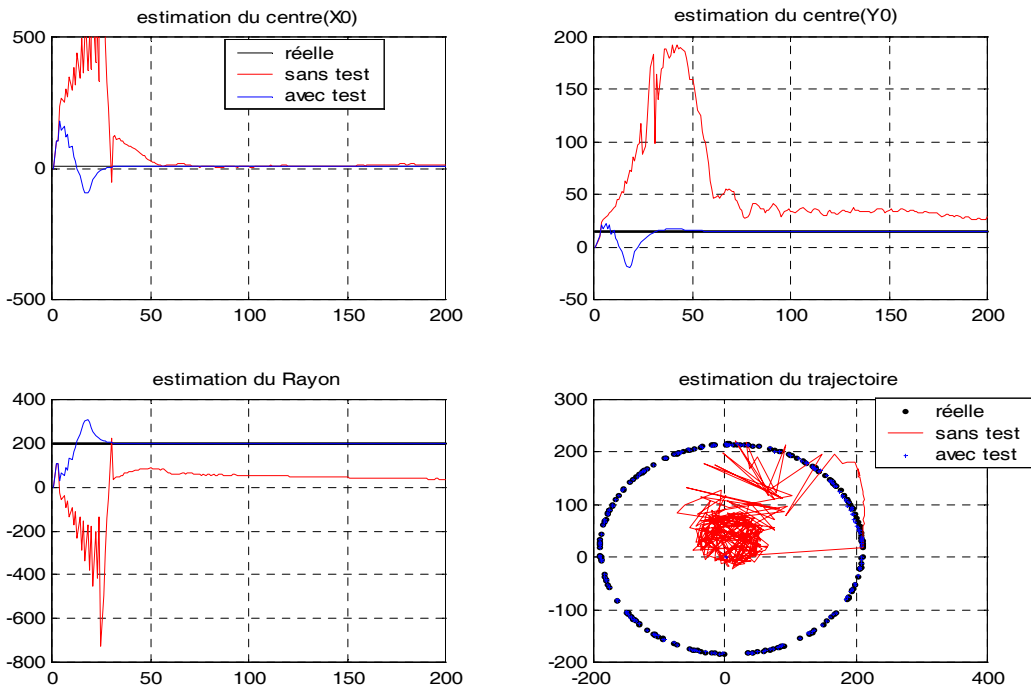


Figure (II.17) : Estimation des paramètres de trajectoire avec sauts en accélération sur un cercle

II.7 Conclusion

Au niveau de ce chapitre, nous avons pu adapter l'algorithme du GLR, qui est souvent utilisé en radar pour la détection de cible et pour éviter les fausses alarmes, au problème de rupture de mouvement dans le cas de la poursuite de cibles manoeuvrantes. Nous avons également montré l'opportunité d'utiliser ce test pour à la fois détecter d'éventuels saut au niveau du vecteur d'état, d'estimer l'instant d'apparition du saut, d'évaluer son amplitude et enfin de corriger les prédictions et estimées futures, pour garantir la convergence du filtre de poursuite.

Le problème d'initialisation, constitue l'un des inconvénients majeurs du filtre de kalman étendu. Au niveau de ce chapitre nous avons tenter de palier à cet aléa en proposant de lancer une batterie de filtre où chacun des filtres est initialisé différemment mais en tenant compte des différentes contraintes et aptitudes des cibles à poursuivre.

Les résultats de simulation, en considérant différents scénarii, ont été probants et ont montré l'efficacité de nos approches pour résoudre les problèmes de sporadiques ruptures de mouvement et d'initialisation du filtre de kalman étendu.

Néanmoins, pour résoudre le problème de rupture de mouvement, nous avons émis un certain nombre d'hypothèses restrictives. En effet, nous avons considéré que les sauts ne sont pas récurrents (ils ne se présentent que rarement), et lorsqu'il y a saut, il se manifeste sous forme d'un brusque changement d'amplitude d'un paramètre du vecteur d'état (notamment la vitesse). Le problème qui reste posé, consiste à n'émettre aucune hypothèse à priori; en effet qu'en est il du cas où les ruptures de mouvement sont fréquentes et quelle serait l'approche à adopter lorsque c'est complètement le modèle qui change et pas seulement un paramètre qui change d'amplitude.

Dans le chapitre suivant, nous allons nous intéresser à cette problématique, en essayant de faire un tour d'horizon des différentes approches existantes dans la littérature pour résoudre ce problème et en proposant une technique capable de solutionner les problèmes qui restent en suspens.

Chapitre III

Approche Modèles Multiples Pour la Poursuite de Cibles Manœuvrantes

III.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 [3], les méthodes d'associations des données [4]. 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 manoeuvrante, le succès du filtre de Kalman standard peut être limité; des structures alternatives utilisant plusieurs filtres de Kalman en parallèle ont montré un succès dans ce domaine, notamment lorsque les modèles considérés sont linéaires.

III.2 Estimation à Modèles Multiples

Dans le domaine de la poursuite de cibles, il y a deux classes fondamentales de modèles : manoeuvrant et non manoeuvrant [3,9]. Les modèles non manoeuvrants sont employés pour exploiter le fait que la plupart des avions volent le long de chemins droits (trajectoires rectilignes) plus de temps; une telle connaissance introduit la certitude intrinsèque dans le problème d'estimation, qui peut être employée pour réduire la largeur de bande du filtre de poursuite et pour augmenter considérablement la précision des états estimés.

Les modèles manoeuvrants sont nécessaires dans un système d'estimation pour décrire le mouvement de la cible. La variété des manoeuvres d'une cible peut (en particulier dans un arrangement militaire) élever le niveau d'incertitude dans le système).

Fondamentalement, les traqueurs de cibles peuvent utiliser deux stratégies pour s'adapter aux changements des modèles dynamiques. La première approche [80] est d'utiliser la mesure pour estimer les paramètres inconnus de manoeuvre (des méthodes employant souvent des fenêtres de type glissant, comme vu au chapitre II), et corriger alors les états estimés en utilisant ces paramètres. L'inconvénient de cette méthode est qu'elle est lente pour s'adapter au changement; elle prend plusieurs périodes d'échantillonnages après le début d'une manoeuvre pour pouvoir estimer les paramètres de manoeuvre avec n'importe quel niveau d'exactitude.

La deuxième approche [69,70] pour s'adapter aux changements de la dynamique de cible est d'utiliser une banque parallèle d'estimateurs, chacun accordé à une condition de fonctionnement différente, et puis de combiner les sorties dans une estimation moyenne pondérée basée sur l'exécution apparente de chaque filtre élémentaire. Cette dernière architecture a un avantage important, par rapport à l'ancienne concernant la vitesse d'adaptation. Pratiquement toutes les techniques à modèles multiples, partagent cette 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.

III.2.1 Approche à Modèles Multiples (cas de non changement de modèles)

Supposons que la cible peut suivre un modèle de mouvement parmi r possibles. L'approche à modèles multiples est illustrée par la figure suivante :

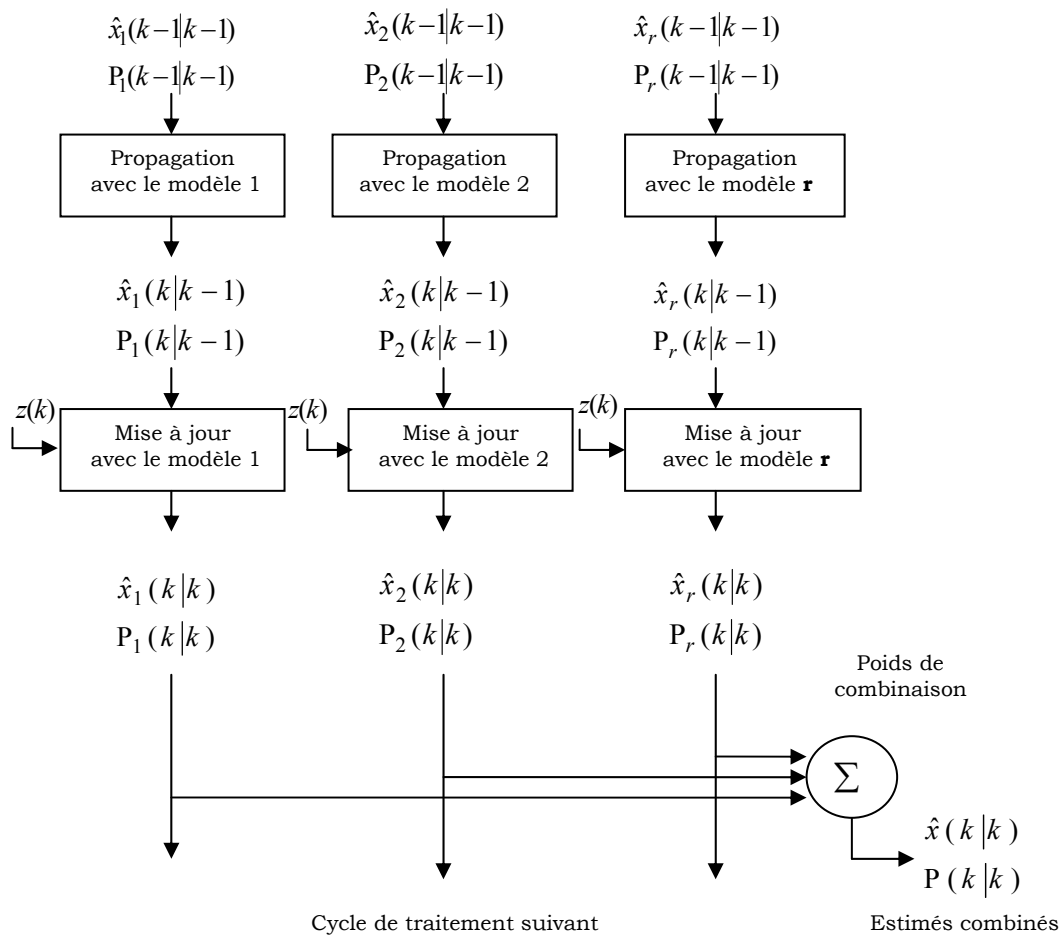


Figure (III.1) : schéma fonctionnel de l'algorithme d'estimation à modèles multiples fixes (cas de non changement de modèles)

Comme l'indique le schéma fonctionnel ci-dessus, l'algorithme d'estimation à modèles multiples, dans le cas de non changement de modèles dans le temps, se déroule selon les phases décrites ci-après.

III.2.1.1 Calcul des probabilités des modèles

L'événement M_j (Modèle j) est défini pour représenter la condition que le modèle j est en vigueur. 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 :

$$\mu_j(k) = P\{M_j | Z^k\} \quad (III.1)$$

Soit $z(k)$ la mesure courante, en appliquant la règle de Bayes à $z(k)$ et M_j , l'équation précédente devient :

$$\begin{aligned} \mu_j(k) &= P\{M_j | Z^{k-1}, z(k)\} \\ &= \frac{f\{M_j, z(k) | Z^{k-1}\}}{f\{z(k) | Z^{k-1}\}} \\ &= \frac{f\{z(k) | M_j, Z^{k-1}\} P\{M_j | Z^{k-1}\}}{f\{z(k) | Z^{k-1}\}} \end{aligned} \quad (III.2)$$

Où la notation $P\{\cdot\}$ se rapporte à la probabilité d'un événement discret, tandis que $f\{\cdot\}$ se rapporte à la fonction de densité de probabilité d'une variable continue. Le dénominateur de l'équation (III-2) peut être augmenté en utilisant le développement de probabilité totale, nous aurons alors :

$$f\{z(k) | Z^{k-1}\} = \sum_{i=1}^r f\{z(k) | M_i, Z^{k-1}\} P\{M_i | Z^{k-1}\} \quad (III.3)$$

Où r est le nombre de modèles présumés (et ainsi le nombre de filtres élémentaires dans la structure). Ceci donne l'équation récursive suivante pour les probabilités des modèles $\mu_j(k)$:

$$\mu_j(k) = \frac{f\{z(k) | M_j, Z^{k-1}\} \mu_j(k-1)}{\sum_{i=1}^r f\{z(k) | M_i, Z^{k-1}\} \mu_i(k-1)} \quad (III.4)$$

Le calcul de $f\{z(k) | M_j, Z^{k-1}\}$ est un problème facile pour le cas de modèles qui ne changent pas avec le temps, cette fonction de densité représente la relation entre la mesure courante et l'histoire des mesures

précédentes. En supposant que le modèle de mesure du filtre de Kalman linéaire standard, cette entité est évaluée comme suit :

$$f\{z(k)|M_j, Z^{k-1}\} = N\{z(k); H_j \hat{x}_j(k/k-1), H_j P_j(k/k-1) H_j^T + R_j\} \quad (\text{III.5})$$

Où $\hat{x}_j(k/k-1)$ et $P_j(k/k-1)$ représentent respectivement l'état prédit et sa covariance basée sur le modèle j , H_j et R_j sont respectivement la matrice de mesure et sa covariance d'erreur toujours sous le modèle j .

III.2.1.2 Calcul des estimés combinés

Chaque filtre basé sur le modèle M_j a pour sorties :

- ✓ L'estimée de l'état du modèle \hat{x}_j ,
- ✓ la covariance associée P_j ,
- ✓ la fonction de vraisemblance du modèle Λ_j .

Après que les filtres soient initialisés, ils fonctionnent récursivement sur leurs propres estimés. Leurs fonctions de vraisemblance sont employées pour faire la mise à jour des probabilités des modèles, ces probabilités sont utilisées pour combiner les états estimés des modèles conditionnés et leurs covariances.

Sous les suppositions ci-dessus la PDF de l'état du système est une mixture gaussienne [4] avec r termes :

$$f\{x(k)|Z^k\} = \sum_{j=1}^r \mu_j(k) N\{x(k); \hat{x}_j(k/k), P_j(k/k)\} \quad (\text{III.6})$$

$$\text{Où } N\{\cdot\} = |2\pi P_j(k/k)|^{-\frac{1}{2}} \cdot \exp\left\{-\frac{1}{2} [x(k) - \hat{x}_j(k)]^T P_j^{-1}(k/k) [x(k) - \hat{x}_j(k)]\right\} \quad (\text{III.7})$$

L'estimation de la moyenne conditionnelle est calculée comme une moyenne pondérée des estimés des filtres élémentaires en utilisant les probabilités des modèles $\mu_j(k)$ comme poids :

$$\hat{x}(k/k) = \sum_{j=1}^r \mu_j(k) \hat{x}_j(k/k) \quad (\text{III.8})$$

La covariance de cet estimé peut également être calculée en utilisant une moyenne pondérée, mais en ajoutant un terme de correction qui tient compte de la propagation des différents estimés :

$$P(k/k) = \sum_{j=1}^r \mu_j(k) \left\{ P_j(k/k) + [\hat{x}_j(k/k) - \hat{x}(k/k)] [\hat{x}_j(k/k) - \hat{x}(k/k)]^T \right\} \quad (\text{III.9})$$

III.2.2 Approche Modèles Multiples (cas avec changement de modèles)

Pour tenir compte des changements de modèles, le modèle en vigueur est autorisé de changer à n'importe quel instant d'échantillonnage, et des événements de l'histoire du modèle sont employés pour caractériser le comportement transitoire du système avec le temps. De tels événements sont décrits comme suit :

$$M^{k,l} = \{M_{i_{1,l}}, M_{i_{2,l}}, \dots, M_{i_{k,l}}\} \quad l=1, \dots, r^k \quad \text{(III.10)}$$

avec $1 \leq i_{q,l} \leq r \quad q=1, \dots, k$

Cette notation est interprétée comme suit : Pour avoir à l'instant k un modèle donné, parmi les r modèles possibles, nous pouvons avoir comme historique l séquences, de transition de modèles, possibles.

Si des transitions sont permises pour chaque r modèles à n'importe quel instant, alors chaque événement de l'histoire du modèle à l'instant k provoquera r nouveaux événements à l'instant $k+1$, par conséquent le nombre d'histoires des modèles possibles augmente exponentiellement avec le temps selon r^k .

Par exemple, avec $r=2$ à l'instant $k=2$ on a $r^k = 4$ séquences possibles (histoires)

l	$i_{1,l}$	$i_{2,l}$
1	1	1
2	1	2
3	2	1
4	2	2

Il sera supposé que le processus de saut du modèle est un processus de Markov (chaîne de Markov) avec des probabilités de transitions des modèles connus :

$$p_{ij}^{\Delta} = P\{M(k) = M_j | M(k-1) = M_i\} \quad \text{(III.11)}$$

Ces probabilités de transitions des modèles seront supposées invariantes dans le temps et indépendantes de l'état de base. En d'autres termes nous considérerons une chaîne de Markov homogène. La PDF de l'état conditionné de la cible sur les mesures doit alors être calculée comme le développement de la probabilité totale en considérant tous les événements de l'histoire du modèle :

$$f\{x(k) | Z^k\} = \sum_{l=1}^{r^k} f\{x(k) | M^{k,l}, Z^k\} P\{M^{k,l} | Z^k\} \quad \text{(III.12)}$$

La probabilité de l'histoire du modèle $P\{M^{k,l}, Z^k\}$ est développée comme suit:

$$\begin{aligned}
P\{M^{k,l}, Z^k\} &= P\{M^{k,l} | z(k), Z^{k-1}\} \\
&= \frac{f\{M^{k,l} | z(k), Z^{k-1}\}}{f\{z(k) | Z^{k-1}\}} \\
&= \frac{f\{z(k) | M^{k,l}, Z^{k-1}\} P\{M^{k,l} | Z^{k-1}\}}{f\{z(k) | Z^{k-1}\}} \\
&= \frac{f\{z(k) | M^{k,l}, Z^{k-1}\} P\{M_{k,j}, M^{k-1,l'} | Z^{k-1}\}}{f\{z(k) | Z^{k-1}\}} \\
&= \frac{f\{z(k) | M^{k,l}, Z^{k-1}\} P\{M_{k,j} | M^{k-1,l'}, Z^{k-1}\} P\{M^{k-1,l'} | Z^{k-1}\}}{f\{z(k) | Z^{k-1}\}} \tag{III.13}
\end{aligned}$$

Où l est l'index de l'histoire du modèle courant (entre 1 et r^k), l' est l'index de l'histoire du modèle précédent (entre 1 et r^{k-1}) et j est l'index du modèle courant (entre 1 et r) présumé par l'évènement de l'histoire du modèle $M^{k,l}$.

Le dénominateur est développé comme le développement de la probabilité totale au-dessus de tous les évènements de l'histoire du modèle comme dans l'équation (III-12). La méthode généralement employée pour évaluer les probabilités de l'évènement de l'histoire du modèle, est de supposer que le processus de transition du modèle est un processus de Markov, telle que la probabilité de la transition dépend seulement du nombre de modèles précédents $i_{k-1,l'}$ et non pas de l'histoire du modèle antérieure ou des mesures antérieures :

$$\begin{aligned}
P\{M_{k,j} | M^{k-1,l'}, Z^{k-1}\} &= P\{M_{k,j} | M^{k-1,l'}\} \\
&= P\{M_{k,j} | M_{i_{1,l'}}, M_{i_{2,l'}}, \dots, M_{i_{k-1,l'}}\} \\
&= P\{M_{k,j} | M_{i_{k-1,l'}}\} \\
&\stackrel{\Delta}{=} p_{i_{k-1,l'}, j}(k) \tag{III.14}
\end{aligned}$$

Où $p_{i_{k-1,l'}, j}(k)$ est la probabilité de transition de modèle d'index $i_{k-1,l'}$ à l'instant $k-1$ vers le modèle d'index j à l'instant k (chaque index est un nombre de modèles entre 1 et r). Tandis que l'hypothèse de l'équation (III.14) fournit un mécanisme pour le calcul de probabilité de la séquence du

modèle, le conditionnement dans l'équation (III.13) de probabilité de la nouvelle mesure sur la séquence du modèle produit toujours un nombre exponentiellement croissant d'hypothèses avec le temps. Les algorithmes les plus généralement utilisés sont décrits dans les sections suivantes.

La structure de l'estimateur bayésien changeant (switching model) de plein ordre est décrit au niveau de la figure (III-2). Elle montre l'augmentation du nombre des filtres qui est exigé. La sortie de chaque filtre au cycle de traitement courant doit être traitée dans le cycle de traitement suivant en utilisant chaque modèle, par conséquent le nombre d'opérations de filtrage au k ième cycle est $r^k \hat{x}(0|0)$

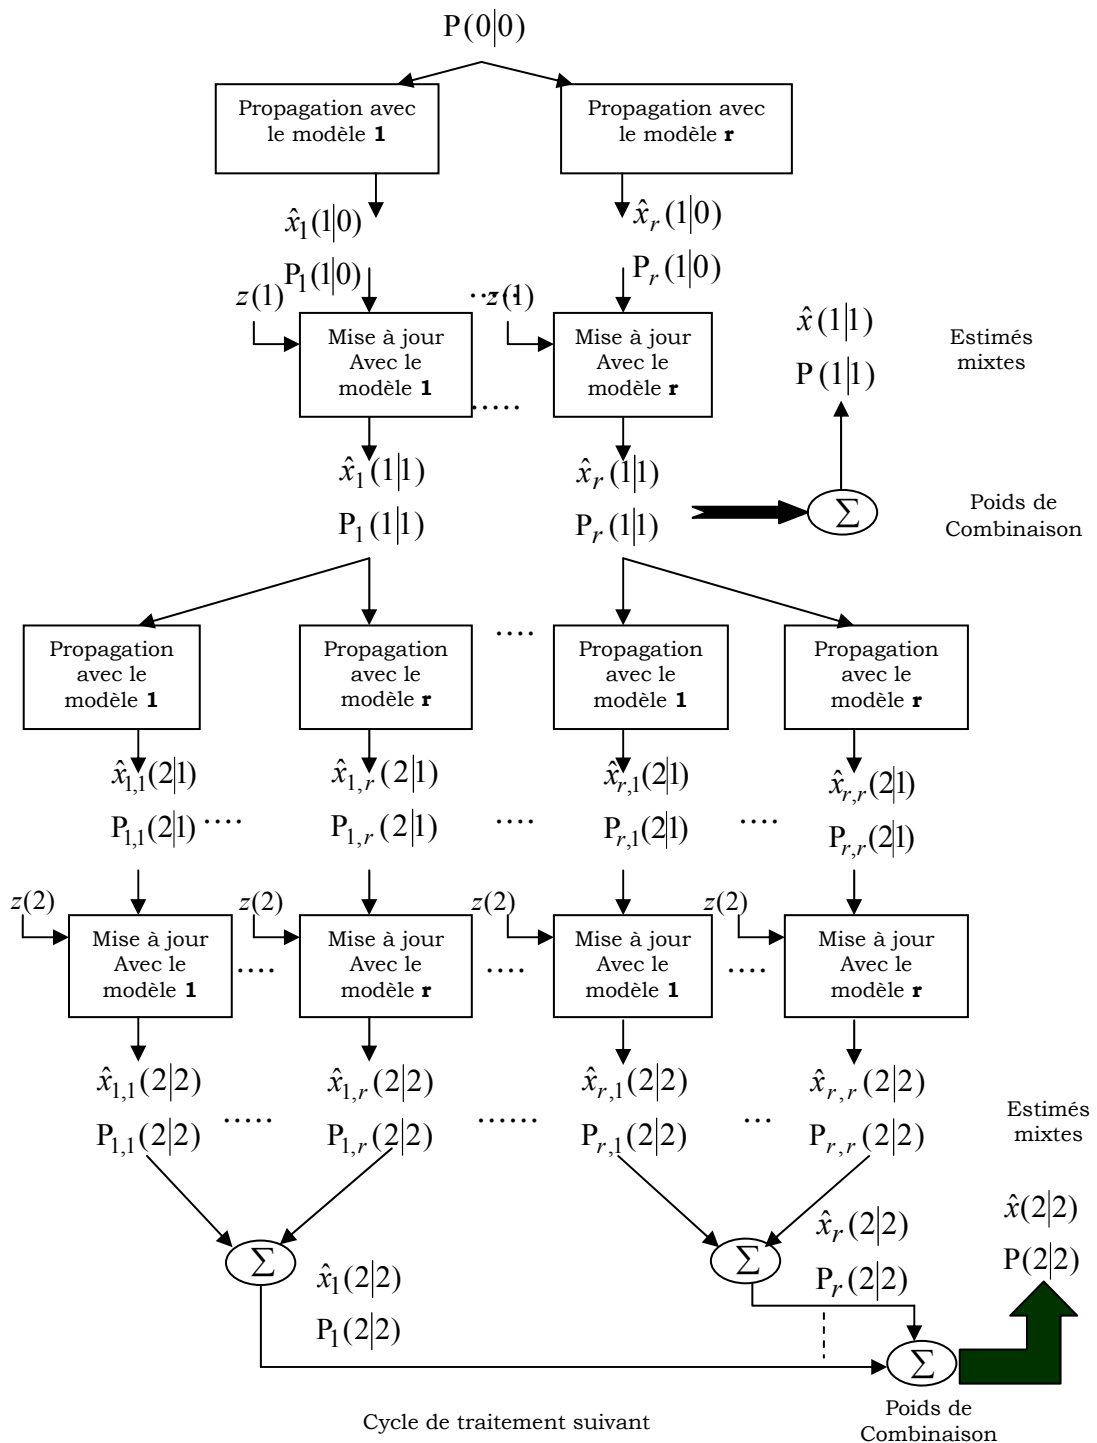


Figure (III.2) : Schéma de l'estimateur Bayésien de plein ordre (cas de changement de modèles)

Cette dernière approche, n'étant pas applicable pratiquement, pour cause d'explosion en exponentiel du nombre de filtres à utiliser, plusieurs versions modifiées de l'algorithme ci-dessus ont vu le jour, dans ce qui suit, nous allons présenter les plus importantes.

III.3 Estimateur Pseudo-Bayésien Généralisé de Premier Ordre (GPB1)

L'estimateur Pseudo-Bayésien généralisé de premier ordre (GPB-1) [3] limite la mémoire des événements de l'histoire ou la séquence des modèles, en combinant les estimés de tous les modèles en un estimé simple à la fin de chaque cycle de traitement. Au début de chaque cycle de traitement, l'information rapportée de l'intervalle de mesure précédent est un simple estimé combiné; la PDF de l'estimation du modèle changeant de l'équation (III-12) :

$$f\{x(k)|Z^k\} = \sum_{l=1}^{r^k} f\{x(k)|M^{k,l}, Z^k\} P\{M^{k,l}|Z^k\}$$

sera modifiée par la version simplifiée :

$$f\{x(k)|Z^k\} = \sum_{j=1}^r f\{x(k)|M_{k,j}, Z^k\} P\{M_{k,j}|Z^k\} \quad (\text{III.15})$$

dont le développement de la probabilité totale au-dessus de l'évènement de l'histoire du modèle entier $M^{k,l}$ est remplacé par le développement au-dessus de l'évènement du modèle simple le plus récent $M_{k,j}$.

Développons l'équation (III-15), nous approchons l'histoire de mesures précédente Z^{k-1} par l'état estimé et sa covariance du cycle de traitement précédent, $\{\hat{x}(k-1|k-1), P(k-1|k-1)\}$:

$$\begin{aligned} f\{x(k)|Z^k\} &= \sum_{j=1}^r f\{x(k)|M_{k,j}, Z^k\} P\{M_{k,j}|Z^k\} \\ &= \sum_{j=1}^r f\{x(k)|M_{k,j}, z(k), Z^{k-1}\} P\{M_{k,j}|Z^k\} \\ &= \sum_{j=1}^r f\{x(k)|M_{k,j}, z(k), \hat{x}(k-1|k-1), P(k-1|k-1)\} P\{M_{k,j}|Z^k\} \quad (\text{III.16}) \end{aligned}$$

En effet, l'approximation des équations (III.15) et (III.16) signifie que l'histoire de transition du modèle entier et l'histoire de mesure sont représentables à travers l'estimation simple du cycle de traitement précédent. Une fois la probabilité conditionnelle du modèle dans l'équation (III.16) a été évaluée en utilisant les développements des équations (III.13) et (III.14), l'estimé combiné est calculé comme indiqué par les équations (III.8) et (III.9), ensuite il suffit de répéter le cycle.

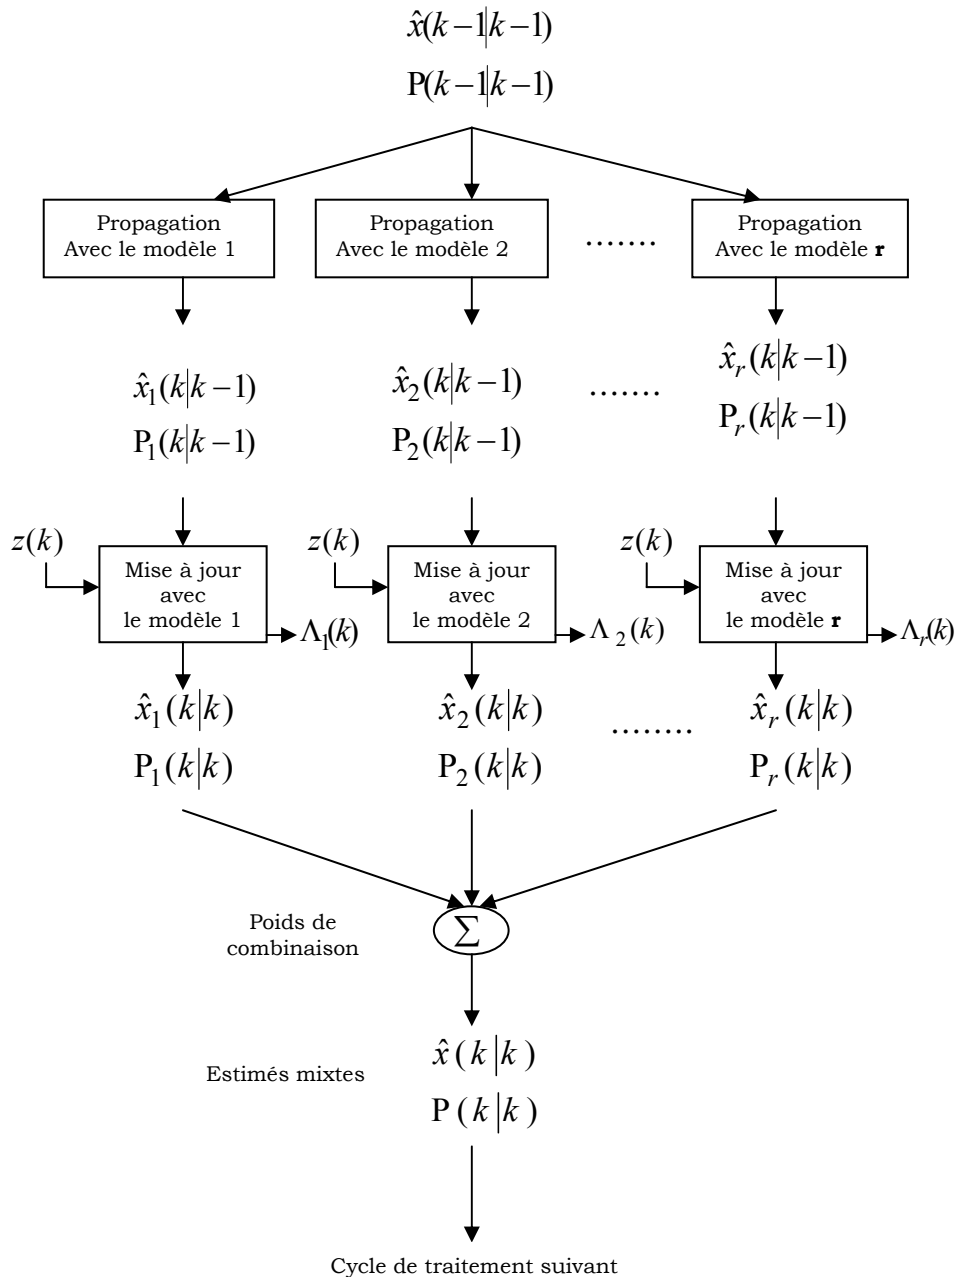


Figure (III.3) : Schéma descriptif de l'algorithme GPB-1

La structure de l'algorithme GPB-1 est illustrée par la figure (III.3), qui exige r filtres en parallèle. La sortie de chaque filtre est l'état estimé du modèle conditionné \hat{x}_j , la covariance associée P_j et la vraisemblance du modèle Λ_j . Les fonctions de vraisemblances sont utilisées pour faire la mise à jour des probabilités des modèles. À chaque cycle de traitement, les sorties

de tous les filtres, sont fusionnées dans un estimé de \hat{x} et de P en utilisant les probabilités des modèles. Elles seront par la suite employées comme entrées de chacun des filtres au prochain cycle de traitement, fournissant une approximation très brute du système optimal représenté sur la figure (III.2). La structure de cet algorithme est:

$$(N_e; N_f) = (1, r) \quad (\text{III.17})$$

où N_e est le nombre d'estimés au début du cycle de l'algorithme et N_f est le nombre de filtres dans l'algorithme.

III.3.1 Algorithme GPB-1

Un cycle de l'algorithme se déroule selon les phases suivantes :

1. filtrage

Avec les entrées $\hat{x}(k-1|k-1)$, nous calculons pour chaque filtre l'estimé $\hat{x}_j(k|k)$ et sa covariance associée $P_j(k|k)$. Les fonctions de vraisemblance définies par :

$$\Lambda_j(k) = p\{z(k)|M_j(k), Z^{k-1}\} \quad (\text{III.18})$$

selon les r filtres, sont évaluées par :

$$\Lambda_j(k) = p\{z(k)|M_j(k), \hat{x}(k-1|k-1), P(k-1|k-1)\} \quad (\text{III.19})$$

$j = 1, \dots, r$

2. mise à jour des probabilités

$$\begin{aligned} \mu_j(k) &= P\{M_j(k)|Z^k\} \\ &= P\{M_j(k)|z(k), Z^{k-1}\} \\ &= \frac{1}{c} p\{z(k)|M_j(k), Z^{k-1}\} P\{M_j(k)|Z^{k-1}\} \\ &= \frac{1}{c} \Lambda_j(k) \sum_{i=1}^r P\{M_j(k)|M_i(k-1), Z^{k-1}\} P\{M_i(k-1)|Z^{k-1}\} \\ &= \frac{1}{c} \Lambda_j(k) \sum_{i=1}^r p_{ij} \mu_i(k-1) \end{aligned} \quad (\text{III.20})$$

où c est la constante de normalisation

$$c = \sum_{j=1}^r \Lambda_j(k) \sum_{i=1}^r p_{ij} \mu_i(k-1) \quad (\text{III.21})$$

3. combinaison des états et des covariances estimés

L'état estimé combiné et sa covariance sont calculés comme suit :

$$\hat{x}(k/k) = \sum_{j=1}^r \hat{x}_j(k/k) \mu_j(k) \quad (\text{III.22})$$

$$P(k/k) = \sum_{j=1}^r \mu_j(k) \left\{ P_j(k/k) + [\hat{x}_j(k/k) - \hat{x}(k/k)] [\hat{x}_j(k/k) - \hat{x}(k/k)]^T \right\} \quad (\text{III.23})$$

III.4 Estimateur Pseudo-Bayésien Généralisé de Deuxième ordre (GPP-2)

L'estimateur Pseudo-Bayésien Généralisé de deuxième ordre (**GBP-2**) [3,4] opère sur des principes semblables à la variante du premier ordre, sauf que la mémoire permet d'ajouter un cycle de traitement additionnel. Dans ce cas, la PDF de l'estimé, simplifiée incorpore le modèle précédent $M_{k-1,i}$ en plus du modèle courant $M_{k,j}$:

$$f\{x(k)|Z^k\} = \sum_{j=1}^r \sum_{i=1}^r f\{x(k)|M_{k,j}, M_{k-1,i}, Z^k\} P\{M_{k,j}, M_{k-1,i}|Z^k\} \quad (\text{III.24})$$

Utilisons l'équation (III-24) et supposons que l'historique $\{M_{k-1,i}, Z^{k-1}\}$ est représentée par les estimés combinés de l'ième modèle dans le cycle de traitement précédent $\{\hat{x}_i(k-1|k-1), P_i(k-1|k-1)\}$, et que (selon le modèle de Markov) la transition du modèle dépend seulement du modèle précédent, et non pas de l'historique de mesure :

$$\begin{aligned} f\{x(k)|Z^k\} &= \sum_{j=1}^r \sum_{i=1}^r f\{x(k)|M_{k,j}, M_{k-1,i}, Z^k\} P\{M_{k-1,i}|M_{k,j}, Z^k\} P\{M_{k,j}|Z^k\} \\ &= \sum_{j=1}^r \sum_{i=1}^r f\{x(k)|M_{k,j}, z(k), \{M_{k-1,i}, Z^{k-1}\}\} \mu_{i|j}(k-1|k) \mu_j(k) \\ &= \sum_{j=1}^r \sum_{i=1}^r f\{x(k)|M_{k,j}, z(k), \{M_{k-1,i}, Z^{k-1}\}\} \\ &\quad \cdot \mu_{i|j}(k-1|k) \mu_j(k) \end{aligned} \quad (\text{III.25})$$

Donc à l'instant $k-1$ il y a r états et covariances estimés, chacun est prédit et mis à jour à l'instant k sous r hypothèses, à savoir :

$$\hat{x}_{ij}(k/k) \stackrel{\Delta}{=} \hat{x}\{k|k; M_j(k), \hat{x}_i(k-1|k-1), P_i(k-1|k-1)\} \quad i, j=1, \dots, r \quad (\text{III.26})$$

$$P_{ij}(k/k) \stackrel{\Delta}{=} P\{k|k; M_j(k), P_i(k-1|k-1)\} \quad i, j=1, \dots, r \quad (\text{III.27})$$

Après la mise à jour, les estimés correspondant au même modèle sont combinés avec les pondérations $\mu_{i|j}(k-1|k)$, donnant lieu à r estimés $\hat{x}_j(k/k)$.

En d'autres termes, les r^2 hypothèses sont fusionnées dans r à la fin de chaque cycle d'estimation. Ceci est illustré à la figure (III.4), qui montre la structure de l'algorithme.

Comparé à la structure de l'algorithme **GPB-1** représentée sur la figure(III.3), 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.

$$(N_e; N_f) = (r; r^2) \tag{III.28}$$

où N_e est le nombre d'estimés au début du cycle de l'algorithme et N_f est le nombre de filtres dans l'algorithme.

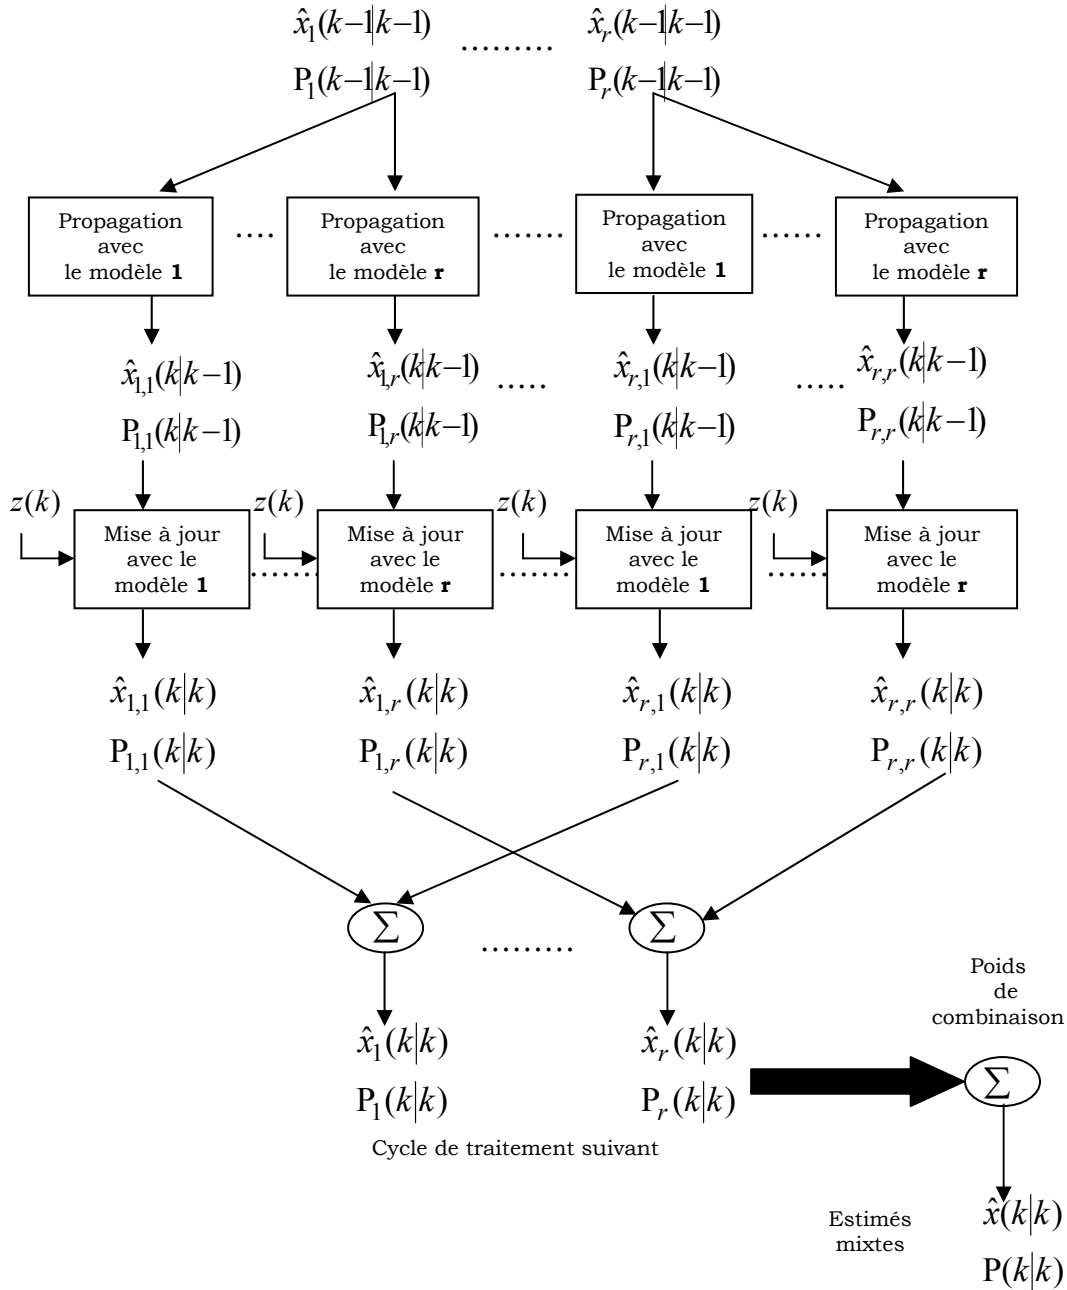


Figure (III.4): Schéma descriptif de l'algorithme GPB-2

III.4.1 Algorithme GPB-2

Un cycle de l'algorithme se déroule selon les phases suivantes :

1. Filtrage

Avec $\hat{x}_i(k-1|k-1)$ et $P_i(k-1|k-1)$ nous calculons $\hat{x}_{ij}(k|k)$ et sa covariance associée $P_{ij}(k|k)$ à travers le filtre assorti de $M_j(k)$. Les fonctions de vraisemblances correspondantes à ces r^2 filtres sont données par :

$$\Lambda_{ij}(k) = f\{z(k)|M_j(k), M_i(k-1), Z^{k-1}\} \quad (\text{III.29})$$

et sont évaluées comme suit :

$$\Lambda_{ij}(k) = f\{z(k)|M_j(k), \hat{x}_i(k-1|k-1), P_i(k-1|k-1)\} \quad i, j = 1, \dots, r \quad (\text{III.30})$$

2. Calcul de probabilités de fusionnement

La probabilité que le modèle i était en effet à l'instant $k-1$ et que le modèle j est en effet à l'instant k conditionnée sur Z^k est :

$$\begin{aligned} \mu_{i|j}(k-1/k) &\stackrel{\Delta}{=} P\{M_i(k-1)|M_j(k), Z^k\} \\ &= P\{M_i(k-1)|z(k), M_j(k), Z^{k-1}\} \\ &= \frac{1}{c_j} P\{z(k), M_j(k)|M_i(k-1), Z^{k-1}\} P\{M_i(k-1)|z^{k-1}\} \\ &= \frac{1}{c_j} P\{z(k)|M_j(k), M_i(k-1), Z^{k-1}\} \\ &\quad \cdot P\{M_j(k)|M_i(k-1), Z^{k-1}\} P\{M_i(k-1)|z^{k-1}\} \end{aligned} \quad (\text{III.31})$$

Donc les probabilités de fusionnement sont :

$$\mu_{i|j}(k-1/k) = \frac{1}{c_j} \Lambda_{ij}(k) p_{ij} \mu_i(k-1) \quad i, j = 1, \dots, r \quad (\text{III.32})$$

avec :

$$c_j = \sum_{i=1}^r \Lambda_{ij}(k) p_{ij} \mu_i(k-1) \quad (\text{III.33})$$

Les probabilités de transition des modèles p_{ij} sont assumées connues, leur choix fait partie du processus de conception de l'algorithme.

3. Le fusionnement

L'état estimé correspondant à $M_j(k)$ est obtenu en combinant les estimés de l'équation (III.26) selon la sommation de l'équation (III.25).

$$\hat{x}_j(k/k) = \sum_{i=1}^r \hat{x}_{ij}(k/k) \mu_{i|j}(k-1/k) \quad j=1, \dots, r \quad (\text{III.34})$$

La covariance correspondante est :

$$P_j(k/k) = \sum_{i=1}^r \mu_{i|j}(k-1/k) \left\{ P_{ij}(k/k) + [\hat{x}_{ij}(k/k) - \hat{x}_j(k/k)] \cdot [\hat{x}_{ij}(k/k) - \hat{x}_j(k/k)]^T \right\} \quad (\text{III.35})$$

4. Mise à jour de probabilité du modèle

$$\begin{aligned} \mu_j(k) &= P\{M_j(k) | z(k), Z^{k-1}\} \\ &= \frac{1}{c} P\{z(k), M_j(k) | Z^{k-1}\} \\ &= \frac{1}{c} \sum_{i=1}^r P\{z(k), M_j(k) | M_i(k-1), Z^{k-1}\} P\{M_i(k-1) | Z^{k-1}\} \\ &= \frac{1}{c} \sum_{i=1}^r P\{z(k) | M_j(k), M_i(k-1), Z^{k-1}\} P\{M_j(k) | M_i(k-1), Z^{k-1}\} \mu_i(k-1) \end{aligned} \quad (\text{III.36})$$

D'où les probabilités de mises à jour de modèles sont :

$$\mu_j(k) = \frac{1}{c} \sum_{i=1}^r \Lambda_{ij}(k) p_{ij} \mu_i(k-1) = \frac{c_j}{c} \quad j=1, \dots, r \quad (\text{III.37})$$

où c_j est décrit par l'équation (III-33) et c est la constante de normalisation

$$c = \sum_{j=1}^r c_j \quad (\text{III.38})$$

5. Combinaison des états estimés et covariances

L'état estimé combiné et sa covariance sont donnés par :

$$\hat{x}(k/k) = \sum_{j=1}^r \hat{x}_j(k/k) \mu_j(k) \quad (\text{III.39})$$

$$P(k/k) = \sum_{j=1}^r \mu_j(k) \left\{ P_j(k/k) + [\hat{x}_j(k/k) - \hat{x}(k/k)] [\hat{x}_j(k/k) - \hat{x}(k/k)]^T \right\} \quad (\text{III.40})$$

III.5 Estimateur à Modèle Multiple Interagissant (IMM)

L'estimateur à modèle multiple interagissant [3, 9,17], plus connu sous son appellation anglo-saxonne *Interacting Multiple Model (IMM)*, est une méthodologie qui réalise une exécution comparable à l'estimateur GPB-2 à l'aide seulement de r filtres élémentaires, plutôt que r^2 . L'algorithme peut être dérivé en considérant les limitations inhérentes au problème.

Si seulement r filtres élémentaires sont permis, alors l'entrée au j 'ième filtre devrait être la meilleure estimation de l'état à l'instant $k-1$, conditionnée sur l'événement que le modèle j est en vigueur à l'instant k , $f\{x(k-1)|M_{k,j},Z^{k-1}\}$. En utilisant cette expression comme point de départ, nous suivons une itération simple de l'algorithme, à travers le calcul de la même fonction à la période d'échantillonnage suivante.

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

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

$$f\{x(k)|Z^k\} = \sum_{j=1}^r f\{x(k)|M_{k,j},Z^k\}P\{M_{k,j}|Z^k\} \quad (\text{III.41})$$

Le but de l'entremêlement est ainsi de masser l'équation (III-41) dans le développement nécessaire à l'entrée du prochain cycle de traitement :

$$f\{x(k)|Z^k\} = \sum_{i=1}^r f\{x(k)|M_{k+1,i},Z^k\}P\{M_{k+1,i}|Z^k\} \quad (\text{III.42})$$

Le dernier facteur dans l'équation (III-42) est facilement évalué en utilisant l'hypothèse de Markov selon l'équation (III-14):

$$\begin{aligned} P\{M_{k+1,i}|Z^k\} &= \sum_{j=1}^r P\{M_{k+1,i}|M_{k,j},Z^k\}P\{M_{k,j}|Z^k\} \\ &= \sum_{j=1}^r P\{M_{k+1,i}|M_{k,j}\}P\{M_{k,j}|Z^k\} \end{aligned} \quad (\text{III.43})$$

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

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

alors l'équation (III-43) est simplement une multiplication de la matrice $T(k+1|k)$ par le vecteur dont les composantes sont les probabilités $P\{M_{k,j}|Z^k\}$.

Le facteur principal dans la somme de l'équation (III-42) est alors augmenté en utilisant le théorème de probabilité totale :

$$f\{x(k)|M_{k+1,i},Z^k\} = \sum_{j=1}^r \{x(k)|M_{k+1,i},M_{k,j},Z^k\}P\{M_{k,j}|M_{k+1,i},Z^k\} \quad (\text{III.44})$$

Où les probabilités de transition sont calculées par :

$$\begin{aligned}
 P\{M_{k,j}|M_{k+1,i},Z^k\} &= \frac{P\{M_{k,j},M_{k+1,i}|Z^k\}}{P\{M_{k+1,i}|Z^k\}} \\
 &= \frac{P\{M_{k+1,i}|M_{k,j},Z^k\}P\{M_{k,j}|Z^k\}}{P\{M_{k+1,i}|Z^k\}} \\
 &= \frac{P\{M_{k+1,i}|M_{k,j},Z^k\}P\{M_{k,j}|Z^k\}}{\sum_{n=1}^r P\{M_{k+1,i}|M_{k,n},Z^k\}P\{M_{k,n}|Z^k\}} \quad (III.45)
 \end{aligned}$$

Selon l'hypothèse de Markov, la probabilité de transition $P\{M_{k+1,i}|M_{k,j},Z^k\}$ ne dépend pas de l'historique des mesures Z^k . Supposant que l'historique Z^k de l'estimateur est convenablement modelé par les r estimés du cycle de traitement précédent (chaque estimé conditionné sur un modèle différent $M_{k,j}$), l'équation (III-44) est alors approximée par une densité gaussienne simple :

$$\begin{aligned}
 f\{x(k)|M_{k+1,i},Z^k\} &\approx \sum_{j=1}^r f\{x(k)|M_{k+1,i},\hat{x}_j(k/k),P_j(k/k)\}P\{M_{k,j}|M_{k+1,i},Z^k\} \\
 &\approx N\{x(k); \hat{x}^i(k/k), P^i(k/k)\} \quad (III.46)
 \end{aligned}$$

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

$$\begin{aligned}
 \hat{x}^i(k/k) &= \sum_{j=1}^r P\{M_{k,j}|M_{k+1,i},Z^k\} \hat{x}_j(k/k) \quad i = 1, \dots, r \\
 P^i(k/k) &= \sum_{j=1}^r P\{M_{k,j}|M_{k+1,i},Z^k\} \left\{ P_j(k/k) + \right. \\
 &\quad \left. [\hat{x}_j(k/k) - x^i(k/k)] [\hat{x}_j(k/k) - x^i(k/k)]^T \right\} \quad (III.47)
 \end{aligned}$$

avec :

$$\mu_{i|j}(k/k) = P\{M_{k,j}|M_{k+1,i},Z^k\} \quad (III.48)$$

Les probabilités à posteriori des modèles $P\{M_{k,j}|Z^k\}$ exigées par l'équation (III-45) sont récursivement calculées en utilisant les expressions :

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

$$= \frac{f\{z(k)|M_{k,j}, Z^{k-1}\}P\{M_{k,j}|Z^{k-1}\}}{f\{z(k)|Z^{k-1}\}} \quad (\text{III.49})$$

Comme illustré dans l'équation (III-43), $P\{M_{k,j}, Z^{k-1}\}$ peut être augmentée ou développée en utilisant le théorème de la probabilité totale :

$$\begin{aligned} P\{M_{k,j}|Z^{k-1}\} &= \sum_{i=1}^r P\{M_{k,j}|M_{k-1,i}, Z^{k-1}\}P\{M_{k-1,i}|Z^{k-1}\} \\ P\{M_{k,j}|Z^{k-1}\} &= \sum_{i=1}^r P\{M_{k,j}|M_{k-1,i}\}P\{M_{k-1,i}|Z^{k-1}\} \end{aligned} \quad (\text{III.50})$$

où l'hypothèse que la probabilité de transition du modèle ne dépend pas de l'historique des mesures est de nouveau adoptée.

Ainsi en substituant dans l'équation (III-50) et en augmentant le dénominateur en utilisant le théorème de la probabilité totale, l'équation (III-39) devient :

$$P\{M_{k,j}|Z^k\} = \frac{f\{z(k)|M_{k,j}, Z^{k-1}\} \sum_{i=1}^r P\{M_{k,j}|M_{k-1,i}\}P\{M_{k-1,i}|Z^{k-1}\}}{\sum_{n=1}^r f\{z(k)|M_{k,n}, Z^{k-1}\}P\{M_{k,n}|Z^{k-1}\}} \quad (\text{III.51})$$

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

Selon les techniques à modèles multiples précédentes, l'estimation combinée est calculée à chaque cycle de traitement pour donner la sortie de l'estimateur. Un schéma fonctionnel de l'algorithme IMM est indiqué sur la figure (III.5). La structure est très semblable à celles des modèles fixes (cas de non changement de modèles) représentée sur la figure (III.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 $\mu_{i|j}(k|k)$, appelées probabilités mixtes [3].

$$\text{La structure de l'algorithme IMM est } (N_e; N_f) = (r; r) \quad (\text{III.52})$$

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

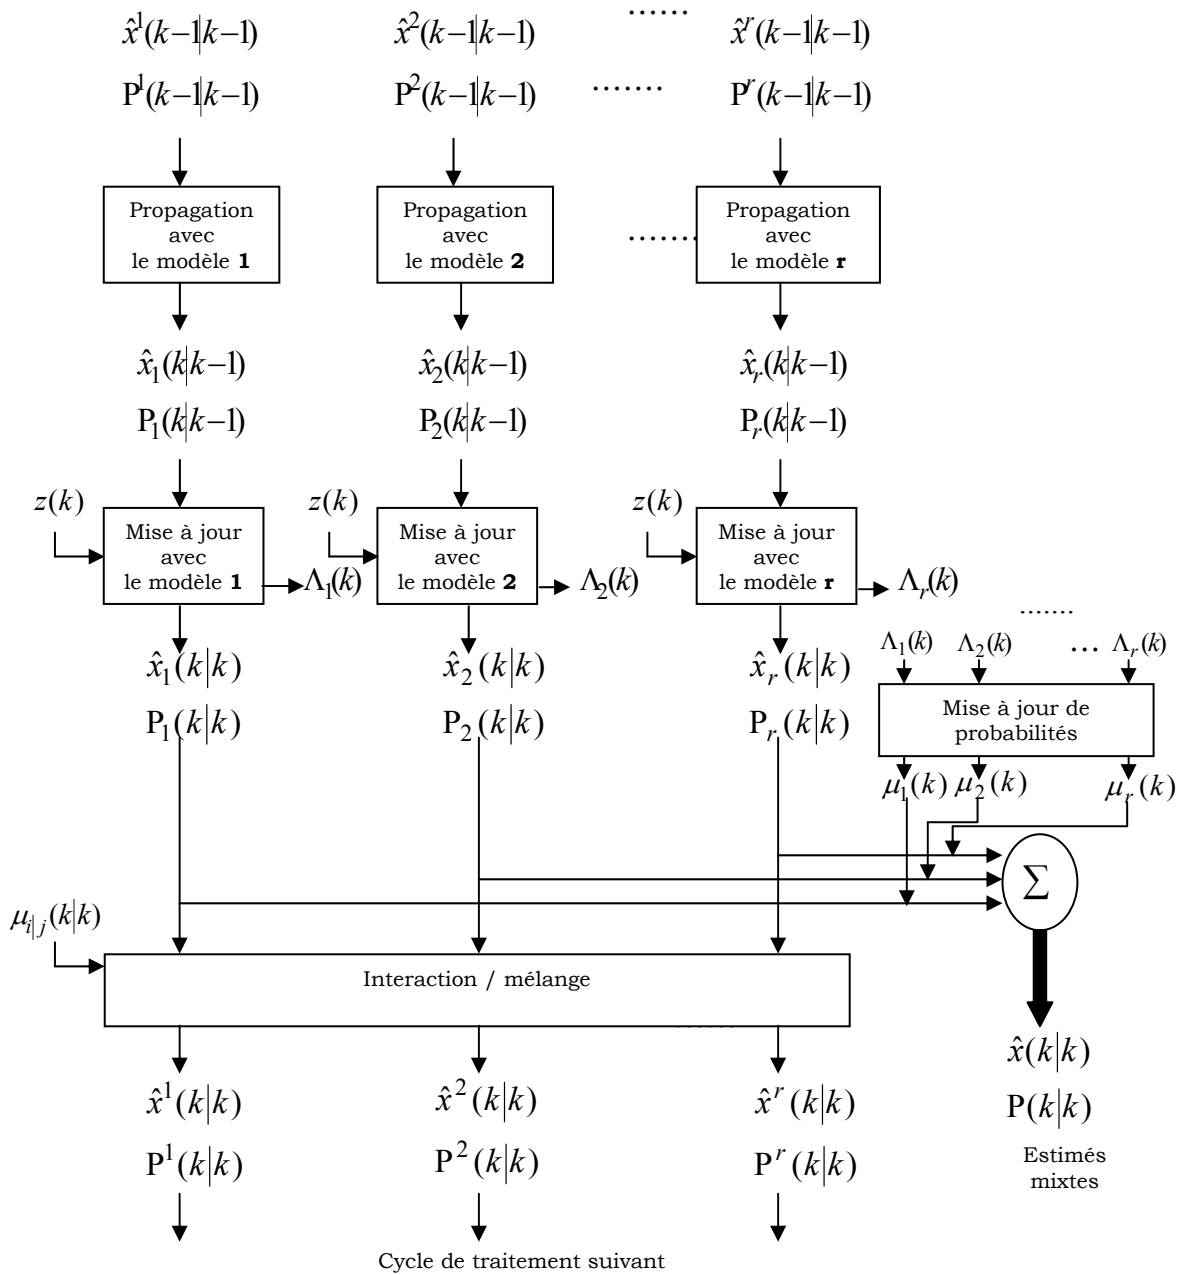


Figure (III.5) : Schéma descriptif de l'algorithme IMM

III.6 Conclusion

Au niveau de ce chapitre, nous avons présenté les approches d'estimation à modèles multiples généralement utilisées. L'estimateur à modèles multiples traditionnel est fondé sur l'hypothèse que le modèle en vigueur ne change pas avec le temps; cependant, si nous tenons compte des changements de modèles, c'est à dire nous admettons que le modèle en vigueur est autorisé de changer à n'importe quel instant, ces changements ou modifications prolongent l'algorithme pour fournir des performances adéquates dans un environnement de modèles changeants (switching model). Tous les estimateurs des modèles changeants utilisent un modèle de Markov pour des probabilités de transition; l'algorithme le plus généralement utilisé et qui fournit une performance semblable au GPB-2 à une fraction du coût de calcul est l'IMM. Malheureusement, ce dernier est conçu pour le cas de modèles linéaires, le problème qui reste posé est de savoir si l'utilisation de ce dernier peut être envisagé dans le cas de modèles non linéaires. C'est ce qui fera l'objet du prochain chapitre, où nous décrivons notre contribution dans ce sens.

Chapitre IV

Extension de l'IMM au Cas de Modèles Non-Lineaires

IV.1 Introduction

Comme mentionné au chapitre précédent, l'algorithme à modèles multiples interagissant (IMM), constitue une solution efficace au problème de la poursuite de cibles manoeuvrantes. Cependant ce dernier est conçu pour le cas de modèles linéaires. Comme les cibles à traquer ne suivent pas nécessairement des modèles de mouvements linéaires (ils sont souvent non linéaires), l'algorithme IMM trouve son champ d'application restreint. Dans une optique d'extension et de généralisation de l'utilisation de cet algorithme, nous allons proposer dans ce présent chapitre une modification de ce dernier afin de le rendre applicable même dans le cas où la cible suit des modèles de mouvement non linéaires.

Le filtre de Kalman constitue le noyau de base de l'algorithme IMM standard (modèles linéaires), une première idée (évidente) qui peut nous venir à l'esprit pour adapter cet algorithme au cas non linéaire, est l'utilisation du filtre de kalman étendu (en anglais, Extended Kalman Filter : EKF), qui consiste à linéariser les modèles non linéaires. Cependant, avant même d'envisager cette solution, nous avons eu des appréhensions quant à l'efficacité de cette approche. En effet, de sérieuses réserves peuvent être émises quant aux limitations de l'EKF, dont nous pouvons citer :

- ✓ La linéarisation peut mener à une instabilité des filtres si l'hypothèse de linéarité locale n'est pas satisfaite,
- ✓ La linéarisation des matrices Jacobiennes est souvent difficile et amène une complexité d'implémentation,
- ✓ La linéarisation n'est possible que si les matrices Jacobiennes existent. En effet, ce n'est souvent pas le cas, lorsque les paramètres du modèle changent brusquement ou lorsque carrément c'est le modèle qui change, situation souvent rencontrée lorsque nous avons affaire à une cible manoeuvrante.

D'après les différentes limitations énumérées ci-dessus, nous nous rendons compte que le véritable problème du filtre de kalman étendu, réside dans la linéarisation des modèles non linéaires. Pour remédier à ce problème, nous nous proposons de combiner l'algorithme IMM avec une version modifiée du filtre de kalman, capable d'estimer tout modèle non linéaire, même en présence de fortes non linéarités, ce filtre est dit "filtre de

kalman sans parfum", et est plus connu sous son nom anglo-saxon "Unscented Kalman Filter : **UKF** " [41].

IV.2 Principe du filtre

IV.2.1 Transformation d'incertitude

Le problème de prédire le futur état ou l'observation du système, peut être exprimé sous la forme suivante. Supposons que x est une variable aléatoire de moyenne \bar{x} et de covariance p_{xx} . Une deuxième variable aléatoire y est liée à x par le fonction non linéaire suivante :

$$y = f(x) \quad (\text{IV.1})$$

Nous souhaitons calculer la moyenne \bar{y} et la covariance p_{yy} de y . Pour calculer les statistiques de y nous devons :

- ✓ déterminer la fonction de densité de distribution transformée,
- ✓ évaluer les statistiques de cette distribution.

Dans quelques cas spéciaux (exemple, lorsque $f[\cdot]$ est linéaire) des solutions exactes existent. Cependant, en général de telles solutions n'existent pas, souvent ce sont des méthodes approximatives qui sont employées. Nous préconisons que la méthode rapporte des statistiques consistantes. Idéalement, celles-ci devraient être efficaces et non biaisées [42]. Les statistiques transformées sont consistantes si l'inégalité suivante est vérifiée :

$$p_{yy} - E[\{y - \bar{y}\}\{y - \bar{y}\}^T] \geq 0 \quad (\text{IV.2})$$

Cette condition est extrêmement importante pour la validité de la méthode de transformation. Si les statistiques ne sont pas consistantes, la valeur de p_{yy} est sous- estimée. Si le filtre de Kalman utilise un ensemble inconsistant de statistiques, il y a la possibilité que le filtre diverge. Pour que la transformation soit plus efficace, la valeur p_{yy} de l'équation (IV.2) devrait être réduite au minimum. Enfin, il est souhaitable que l'estimation soit non biaisée ou $\bar{y} \approx E[y]$.

Le problème de développer une procédure consistante, efficace et non biaisée de transformation peut être examiné en considérant le développement en séries de Taylor de l'équation (IV.1) au voisinage de \bar{x} . Cette série peut s'exprimer par :

$$\begin{aligned} f(x) &= f(\bar{x} + \delta x) \\ &= f(\bar{x}) + \nabla f \delta x + \frac{1}{2} \nabla^2 f \delta x^2 + \frac{1}{3!} \nabla^3 f \delta x^3 + \frac{1}{4!} \nabla^4 f \delta x^4 + \dots \end{aligned} \quad (\text{IV.3})$$

Où δx est une variable aléatoire gaussienne de moyenne nulle et de covariance p_{xx} , et $\nabla^n f \delta x^n$ est le terme approprié d'ordre n dans les séries de Taylor multidimensionnelles. En prenant les espérances, nous pouvons montrer que la moyenne et la covariance transformées sont :

$$\bar{y} = f(\bar{x}) + \frac{1}{2} \nabla^2 f p_{xx} + \frac{1}{4!} \nabla^4 f E[\delta x^4] + \dots \quad (\text{IV.4})$$

$$p_{yy} = \nabla f p_{xx} \nabla f^T + \frac{1}{2 \times 4!} \nabla^2 f (E[\delta x^4] - E[\delta x^2 p_{yy}] - E[p_{yy} \delta x^2] + p_{yy}^2) (\nabla^2 f)^T + \frac{1}{3!} \nabla^3 f E[\delta x^4] (\nabla f)^T + \dots \quad (\text{IV.5})$$

Les moments et les dérivés peuvent être évalués correctement jusqu'au $n^{\text{ième}}$ ordre, la moyenne est bien correcte jusqu'à l'ordre n . Des commentaires également semblables se retiennent pour l'équation de covariance, bien que la structure de chaque terme soit plus compliquée. Puisque chaque terme dans la série est mesuré par un terme graduel plus petit, les termes d'ordre inférieur dans les séries sont susceptibles d'avoir le plus grand impact. Donc, la marche à suivre de prédiction devrait être concentrée en évaluant les termes d'ordre inférieur. La linéarisation suppose que le deuxième terme et les termes d'ordres supérieurs de δx dans l'équation (IV.3) peuvent être négligés. Sous cette supposition, nous aurons :

$$\bar{y} = f(\bar{x}) \quad (\text{IV.6})$$

$$p_{yy} = \nabla f p_{xx} (\nabla f)^T \quad (\text{IV.7})$$

En comparant ces expressions avec les équations (IV.4) et (IV.5), il est clair que ces approximations sont valables seulement si les termes d'ordres supérieurs dans la moyenne et la covariance sont négligeables. Cependant, dans plusieurs situations pratiques la linéarisation introduit des biais ou des erreurs significatives.

IV.2.2 Filtre de Kalman sans parfum (Unscented Kalman Filter: UKF)

IV.2.2.1 Transformation sans parfum

La transformation sans parfum (Unscented transformation : UT) est une nouvelle technique de calcul des statistiques d'une variable aléatoire qui subit une transformation non linéaire. Elle est fondée sur l'intuition qu'il est plus facile d'approximer une distribution gaussienne que d'approximer une fonction non linéaire ou une transformation arbitraire [42,44]. Cette approche est illustrée dans la figure (IV.1). Un ensemble de points (ou sigma points) sont choisis de sorte que leur moyenne et leur covariance soient \bar{x} et p_{xx} .

La fonction non linéaire est appliquée à chaque point alternativement pour rapporter un nuage de points transformés, \bar{y} et p_{yy} sont leurs statistiques. Bien que cette méthode ait une ressemblance superficielle à des

méthodes de type Monte Carlo, il y a une différence extrêmement importante et fondamentale. Les échantillons ne sont pas choisis au hasard mais plutôt selon un algorithme spécifique et déterministe. Des informations d'ordre supérieur sur la distribution peuvent être capturées en utilisant seulement un nombre très petit de points.




Figure (IV.1) : Principe de la transformation sans parfum

Une variable aléatoire x de dimension n , de moyenne \bar{x} et de covariance p_{xx} est approximée par $2n+1$ points pondérés donnés par :

$$\begin{aligned} \chi_0 &= \bar{x} & W_0 &= \frac{\kappa}{(n + \kappa)} \\ \chi_i &= \bar{x} + \left(\sqrt{(n + \kappa) p_{xx}} \right)_i & W_i &= \frac{1}{2(n + \kappa)} \\ \chi_{i+n} &= \bar{x} - \left(\sqrt{(n + \kappa) p_{xx}} \right)_i & W_{i+n} &= \frac{1}{2(n + \kappa)} \end{aligned} \quad (IV.8)$$

Pour $i = 1, \dots, n$

Où $\kappa \in \mathbb{R}$, $\left(\sqrt{(n + \kappa) p_{xx}} \right)_i$ est la i ème ligne ou colonne de la racine carrée de la matrice $(n + \kappa) p_{xx}$ et W_i le poids associé avec le i ème point, tel que $\sum_{i=0}^{2n} W_i = 1$.

La procédure de transformation est comme suit :

1. la fonction non linéaire f est appliquée à chaque point χ_i pour obtenir l'ensemble de points transformés (sigma) $\{y_i\}_{i=0, \dots, 2n}$

$$y_i = f(\chi_i) \quad (IV.9)$$

2. La moyenne est donnée par la somme pondérée des points transformés,

$$\bar{y} = \sum_{i=0}^{2n} W_i y_i \quad (IV.10)$$

3. La covariance est donnée par,
$$p_{yy} = \sum_{i=0}^{2n} W_i \{y_i - \bar{y}\} \{y_i - \bar{y}\}^T \quad (\text{IV.11})$$

Puisque la moyenne et la covariance de x sont capturées avec précision jusqu' au deuxième ordre, les valeurs calculées de la moyenne et de la covariance de y sont aussi bien correctes jusqu'au deuxième ordre. Ceci signifie que la moyenne est calculée à un ordre supérieur d'exactitude ou de précision que le filtre de Kalman étendu (FKE), tandis que la covariance est calculée au même ordre d'exactitude. Cependant, il y a d'autres avantages d'exécution. Puisque c'est la distribution de x qui est approchée plutôt que $f(\cdot)$, son développement en série n'est pas tronqué à un ordre particulier. Il est possible de montrer que l'algorithme de cette transformation peut incorporer partiellement l'information des ordres plus élevés [44], menant à une plus grande précision.

La moyenne et la covariance sont calculées en utilisant des opérations standard de vecteurs et de matrices. Cela signifie que l'algorithme convient à n'importe quel choix du modèle de processus, et l'implémentation est extrêmement rapide parce qu'il n'est pas nécessaire d'évaluer la Jacobienne contrairement au filtre de kalman étendu.

IV.2.2.2 Filtre sans parfum

Les processus de transformation qui se produisent dans un filtre de Kalman comprennent les étapes suivantes :

- ✓ la prédiction d'un nouvel état du système $\hat{x}(k+1/k)$ et sa covariance associée $p(k+1/k)$. Cette prédiction doit tenir compte des effets du bruit du processus,
- ✓ la prédiction de l'observation prévue $\hat{z}(k+1/k)$ et la covariance d'innovation $p_{yy}(k+1/k)$. Cette prédiction doit inclure les effets du bruit d'observation,
- ✓ Finalement, la prédiction de la matrice de corrélation $p_{xz}(k+1/k)$.

Ces étapes peuvent être facilement adaptées en restructurant légèrement le vecteur d'état et les modèles du processus et d'observation. D'abord, le vecteur d'état est augmenté avec les termes du processus et du bruit pour donner un vecteur d'ordre $n^a=n+q$.

1. Application de l'équation (IV.8) au système augmenté indiqué par l'équation (IV.21) pour créer l'ensemble des points sigma.
2. L'ensemble transformé de points est donné en substituant chaque point à travers le modèle de processus,

$$\chi_i(k+1) = f(\chi_i^a(k/k), u(k), k) \quad (\text{IV.12})$$

3. la moyenne prédite est calculée comme

$$\hat{x}(k+1/k) = \sum_{i=0}^{2n^a} W_i \chi_i(k+1/k) \quad (\text{IV.13})$$

4. et la covariance prédite est calculée comme

$$p(k+1/k) = \sum_{i=0}^{2n^a} W_i \{\chi_i(k+1/k) - \hat{x}(k+1/k)\} \{\chi_i(k+1/k) - \hat{x}(k+1/k)\}^T \quad (\text{IV.14})$$

5. la fonction non linéaire d'observation $h(\cdot)$ est appliquée à chaque point prédit $\chi_i(k+1/k)$ pour obtenir les points $z_i(k+1/k)$,

$$z_i(k+1/k) = h(\chi_i(k+1/k), u(k), k) \quad (\text{IV.15})$$

6. l'observation prédite est calculée par

$$\hat{z}(k+1/k) = \sum_{i=0}^{2n^a} W_i z_i(k+1/k) \quad (\text{IV.16})$$

7. puisque le bruit d'observation est additif et indépendant, la covariance de l'innovation est

$$p_{\gamma\gamma}(k+1/k) = R(k+1/k) + \sum_{i=0}^{2n^a} W_i \{z_i(k+1/k) - \hat{z}(k+1/k)\} \{z_i(k+1/k) - \hat{z}(k+1/k)\}^T \quad (\text{IV.17})$$

8. finalement, la matrice de corrélation est déterminée par

$$p_{xz}(k+1/k) = \sum_{i=0}^{2n^a} W_i \{\chi_i(k+1/k) - \hat{x}(k+1/k)\} \{z_i(k+1/k) - \hat{z}(k+1/k)\}^T \quad (\text{IV.18})$$

Le vecteur d'état par

$$x^a(k) = \begin{bmatrix} x(k) \\ v(k) \end{bmatrix} \quad (\text{IV.19})$$

Le modèle du processus est réécrit en fonction de $x^a(k)$,

$$x(k+1) = f(x^a(k), u(k), k) \quad (\text{IV.20})$$

la transformation sans parfum utilise $2n^a + 1$ points sigma qui sont tirés de:

$$\hat{x}^a(k/k) = \begin{pmatrix} \hat{x}(k/k) \\ 0_q \end{pmatrix} \quad \text{et} \quad p^a(k/k) = \begin{bmatrix} p(k/k) & p_{xv}(k/k) \\ p_{xv}(k/k) & Q(k) \end{bmatrix}. \quad (\text{IV.21})$$

IV.2.2.3 Filtre de Kalman sans parfum normalisé (Scaled Unscented Kalman Filter: SUKF)

Comme décrit précédemment, la transformation sans parfum approxime une variable aléatoire x de dimension n de moyenne \hat{x} et de covariance p par $2n+1$ échantillons. Comme la dimension de l'espace d'état augmente, le rayon de la sphère qui borne tout les points augmente également. Pour réguler ceci, nous opérons comme suit pour mesurer les

points (échantillons) [43]. Les nouveaux points et les poids utilisés pour trouver la moyenne sont :

$$\chi'_i = \chi_0 + \alpha(\chi_i - \chi_0) \quad (IV.22)$$

$$W'_i = \begin{cases} \frac{W_0}{\alpha^2} + 1 - \frac{1}{\alpha^2} & i = 0 \\ \frac{W_i}{\alpha^2} & i \neq 0 \end{cases} \quad (IV.23)$$

la covariance est calculée en utilisant l'ensemble modifié de poids:

$$W''_i = \begin{cases} \frac{W_0}{\alpha^2} + 2 - \frac{1}{\alpha^2} - \alpha^2 + \beta & i = 0 \\ \frac{W_i}{\alpha^2} & i \neq 0 \end{cases} \quad (IV.24)$$

Où α et β sont des paramètres réglables. La moyenne et la covariance sont données par :

$$y'_i = f(\chi'_i) \quad (IV.25)$$

$$\hat{y}' = \sum_{i=0}^{2n} W'_i y'_i \quad (IV.26)$$

$$p'_{yy} = \sum_{i=0}^{2n} W''_i \{y'_i - \hat{y}'\} \{y'_i - \hat{y}'\}^T \quad (IV.27)$$

Il ne reste qu'à placer les paramètres réglables κ , α , et β . En général, il est recommandé de prendre $\beta = 2$ [54].

Pour capturer une partie du terme du quatrième ordre dans le développement en série de Taylor de la covariance, nous choisissons :

$$\alpha = \frac{1}{\sqrt{n}}$$

La matrice de covariance estimée p'_{yy} est garantie d'être semi définie positive si tous les poids non transformés sont non négatifs, ce qui établit la condition $\kappa > 0$. Nous voulons également que les poids transformés soient non négatifs pour la robustesse (si un point a un poids essentiellement négatif, alors une non linéarité peut mener à une moyenne estimée biaisée et covariance gonflée), ce qui établit la condition stricte:

$$\kappa > n^2 - n. \quad (IV.28)$$

Nous choisissons réellement de rendre tous les poids transformés égaux, de sorte que

$$\kappa = n^2 - \frac{n}{2} \quad (IV.29)$$

Le filtre de Kalman sans parfum (UKF) emploie l'UT pour les deux transformations (modèle de processus et fonction d'observation) exigées par le filtre de Kalman. Il fournit une estimation minimum de l'erreur quadratique moyenne (MMSE) de l'état d'un système discret non linéaire [44]. Soit le système défini comme suit :

$$x(k+1) = f(x(k), u(k), v(k), k) \quad (\text{IV.30})$$

$$z(k) = h(x(k), u(k), k) + \omega(k) \quad (\text{IV.31})$$

Où $x(k)$ est l'état du système à l'instant k , $f(k)$ et $h(k)$ sont des fonctions non linéaires, respectivement du processus et de mesure, $u(k)$ est le vecteur d'entrée, $v(k)$ est le bruit de processus, $z(k)$ est l'observation, et $\omega(k)$ est un bruit additif de mesure. v et ω sont supposés de moyennes nulles et:

$$\begin{aligned} E[v(k)v^T(j)] &= \delta_{kj} Q(k) \\ E[\omega(k)\omega^T(j)] &= \delta_{kj} R(k) \\ \delta_{kj} &= 1 \quad \text{pour } k=j \\ E[v(k)\omega^T(j)] &= 0, \quad \forall k, j \end{aligned} \quad (\text{IV.32})$$

Une matrice augmentée de covariance est construite avec p , Q , et R sur la diagonale. Les équations (IV.8) et (IV.21) fournissent alors les points échantillons $\chi'_i(k+1/k)$.

L'état prédit $\hat{x}(k+1/k)$ et sa covariance $p(k+1/k)$ sont donnés par :

$$\chi'_i(k+1/k) = f(\chi'_i(k/k), u(k), k) \quad (\text{IV.33})$$

$$\hat{x}(k+1/k) = \sum_{i=0}^{2n} W'_i \chi'_i(k+1/k) \quad (\text{IV.34})$$

$$p(k+1/k) = \sum_{i=0}^{2n} W''_i \{ \chi'_i(k+1/k) - \hat{x}(k+1/k) \} \{ \chi'_i(k+1/k) - \hat{x}(k+1/k) \}^T \quad (\text{IV.35})$$

L'observation prédite \hat{z} , sa covariance p_{zz} et la corrélation p_{xz} sont estimées comme suit :

$$z_i(k+1/k) = h(\chi'_i(k+1/k), u(k), k+1) \quad (\text{IV.36})$$

$$\hat{z}(k+1/k) = \sum_{i=0}^{2n} W'_i z_i(k+1/k) \quad (\text{IV.37})$$

$$p_{zz} = \sum_{i=0}^{2n} W''_i \{ z_i(k+1/k) - \hat{z}(k+1/k) \} \{ z_i(k+1/k) - \hat{z}(k+1/k) \}^T \quad (\text{IV.38})$$

$$p_{xz} = \sum_{i=0}^{2n} W''_i \{ \chi'_i(k+1/k) - \hat{x}(k+1/k) \} \{ z_i(k+1/k) - \hat{z}(k+1/k) \}^T \quad (\text{IV.39})$$

L'état estimé $\hat{x}(k/k)$ à l'instant k , et sa covariance $p(k/k)$, sont donnés par :

$$p_{\gamma\gamma}(k+1/k) = R(k+1) + p_{zz}(k+1/k) \quad (\text{IV.40})$$

$$K(k+1) = p_{xz}(k+1/k) p_{\gamma\gamma}^{-1}(k+1/k) \quad (\text{IV.41})$$

$$\hat{x}(k+1/k+1) = \hat{x}(k+1/k) + K(k+1)(z(k+1) - \hat{z}(k+1/k)) \quad (\text{IV.42})$$

$$p(k+1/k+1) = p(k+1/k) - K(k+1)p_{\gamma\gamma}(k+1/k)K^T(k+1) \quad (\text{IV.43})$$

où K est le gain de Kalman.

Pour les fonctions linéaires, l'UKF est équivalent au filtre de Kalman standard. La complexité de l'UKF est identique à celle de l'EKF, mais elle est plus précise et n'exige pas la dérivation de n'importe quelles Jacobiennes.

IV.3 Algorithme de poursuite IMM à base de l'UKF (IMMUKF) :

Comme indiqué au niveau de l'introduction, nous allons à présent décrire le nouvel algorithme que nous avons mis en œuvre pour assurer une poursuite efficace d'une cible manoeuvrante, quelque soit le type de modèles suivi (linéaire ou non linéaire), cet algorithme sera désigné par **IMM-UKF**. En effet, cet algorithme est en réalité le résultat d'une combinaison adéquate entre l'algorithme IMM et le filtre de kalman sans parfum UKF, cette combinaison est réalisée dans le but de tirer profit à la fois de l'IMM pour s'assurer à tout instant du véritable modèle de mouvement suivi par la cible, et de l'UKF pour garantir une meilleure estimation malgré les fortes non linéarités qui peuvent caractériser le modèle suivi par la cible.

A chaque instant k , l'état estimé est la combinaison de r estimés calculés selon les r modèles choisis. L'algorithme consiste à mélanger les probabilités des modèles avec les états estimés et leurs covariances à la sortie des filtres. Chaque filtre utilise ces estimés mixtes au début de chaque cycle qui sont illustrés dans la figure (IV.2). L'étape de calcul, des estimés mélangés, est la plus importante de l'algorithme IMM-UKF. Cet algorithme fonctionne suivant les quatre étapes suivantes :

IV.3.1 Mélange d'estimé pour le modèle j

- ✓ Probabilités des transitions : p_{ij}
- ✓ Probabilité du modèle j à l'instant $k-1$: $\mu_j(k-1)$
- ✓ Probabilité prédite du modèle : $\bar{\mu}_j = \sum_i p_{ij}\mu_i(k-1)$ (IV.44)

- ✓ Probabilité mixte du modèle j : $\mu_{i|j} = \frac{p_{ij}\mu_i(k-1)}{\bar{\mu}_j}$ (IV.45)

- ✓ Etat estimé mixte du modèle j :

$$\hat{x}_{0j}(k-1/k-1) = \sum_i x_i(k-1/k-1)\mu_{i|j} \quad (\text{IV.46})$$

✓ Covariance estimée mixte du modèle j :

$$P_{0j}(k-1/k-1) = \sum_i \mu_{i|j} \{P_i(k-1/k-1) + V_{ij}\} \quad (\text{IV.47})$$

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

IV.3.2. Filtrages parallèles

Dans l'étape de filtrage nous faisons appel à l'UKF qui opère en deux étapes, l'une pour la prédiction avant la mesure $z(k)$, et l'autre pour la correction après la présence de la mesure :

Prédiction :

✓ Prédiction d'état :

$$\begin{aligned} x_j^l(k/k-1) &= f(x_{0j}^l(k-1/k-1), k-1) \quad l = 0 : 2n \\ \hat{x}_j(k/k-1) &= \sum_{l=0}^{2n} W_l^l X_j^l(k/k-1) \end{aligned} \quad (\text{IV.48})$$

Où n est la dimension du vecteur d'état.

✓ Prédiction de covariance :

$$P_j(k/k-1) = \sum_{l=0}^{2n} W_l^l \left\{ [x_j^l(k/k-1) - \hat{x}_j(k/k-1)] [x_j^l(k/k-1) - \hat{x}_j(k/k-1)]^T \right\} \quad (\text{IV.49})$$

Correction :

✓ Innovation :

$$\gamma_j(k) = z(k) - \hat{z}_j(k/k-1) \quad (\text{IV.50})$$

$$\text{Où} \quad \hat{z}_j(k/k-1) = \sum_{l=0}^{2n} W_l^l z_j^l(k/k-1)$$

$$\text{Et} \quad z_j^l(k/k-1) = h(x_j^l(k/k-1)) \quad l = 0 : 2n$$

✓ Covariance de l'innovation :

$$S_j(k) = R(k-1) + \sum_{l=0}^{2n} W_l^l [z_j^l(k/k-1) - \hat{z}_j(k/k-1)] [z_j^l(k/k-1) - \hat{z}_j(k/k-1)]^T \quad (\text{IV.51})$$

✓ Gain du filtre :

$$K_j(k) = P_{xz}(k/k-1).S_j^{-1}(k) \quad (\text{IV.52})$$

Avec

$$P_{xz}(k/k-1) = \sum_{l=0}^{2n} W_j^l \left[x_j^l(k/k-1) - \hat{x}_j(k/k-1) \right] \left[z_j^l(k/k-1) - \hat{z}_j(k/k-1) \right]^T$$

✓ Etat estimé :

$$\hat{x}_j(k/k) = \hat{x}_j(k/k-1) + K_j(k) \gamma(k/k-1) \quad (\text{IV.53})$$

✓ Covariance estimée :

$$P_j(k/k) = P_j(k/k-1) - K_j(k) S_j(k) K_j^T(k) \quad (\text{IV.54})$$

IV.3.3 Mise à jour de la probabilité du modèle j

✓ Fonction de vraisemblance du modèle j :

$$\begin{aligned} \Lambda_j(k) &= (2\pi)^{-1} |S_j(k)|^{-\frac{1}{2}} \exp\left(-0.5 \gamma_j^T(k) S_j^{-1}(k) \gamma_j(k)\right) \\ &= N\{\gamma_j(k) : 0, S_j(k)\} \end{aligned} \quad (\text{IV.55})$$

où $N\{\cdot\}$ est la fonction de densité de probabilité normale.

✓ Mise à jour de probabilité du modèle j : $\mu_j(k) = \frac{\bar{\mu}_j \Lambda_j}{\sum_i \bar{\mu}_i \Lambda_i}$ (IV.56)

IV.3.4 Estimation combinée

✓ Etat estimé combiné : $\hat{x}(k/k) = \sum_j \hat{x}_j(k/k) \mu_j(k)$ (IV.57)

✓ Covariance estimée combinée :

$$P(k/k) = \sum_j \mu_j(k) \left\{ P_j(k/k) + \left[\hat{x}(k/k) - \hat{x}_j(k/k) \right] \left[\hat{x}(k/k) - \hat{x}_j(k/k) \right]^T \right\} \quad (\text{IV.58})$$

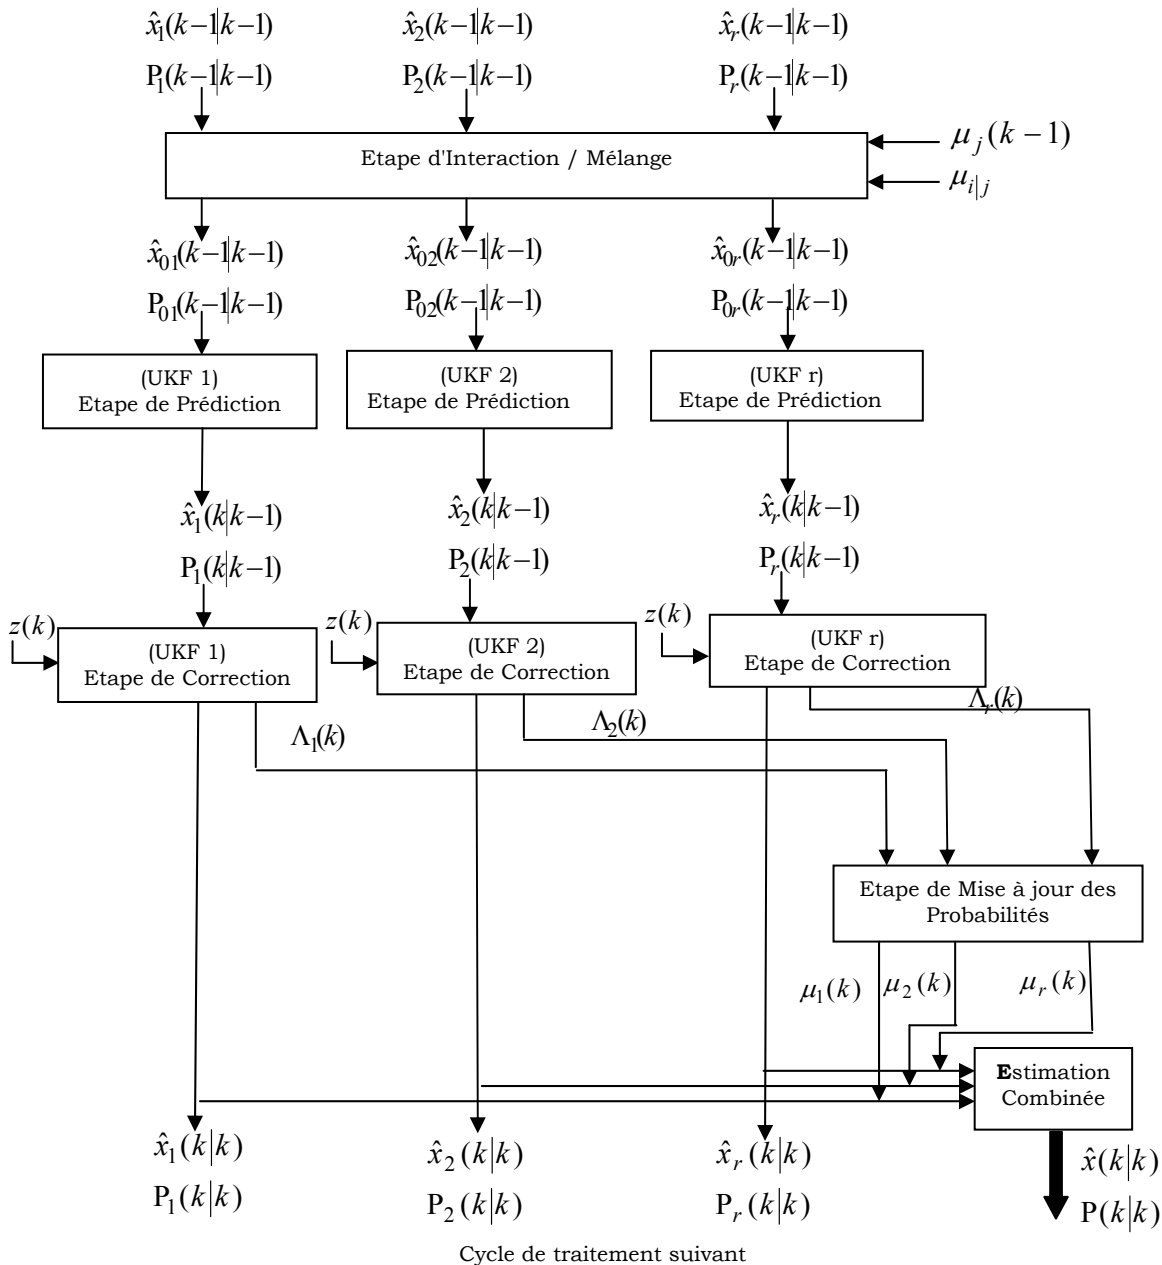


Figure (IV.2) : Algorithme Modèles Multiples Interagissants à base du Filtre de Kalman sans parfum (IMM-UKF).

IV.4 Résultats de Simulation

IV.4.1 Modélisation des trajectoires et du mouvement des cibles

Les modèles considérés sont identiques à ceux définies au chapitre II, néanmoins pour être appliqués au filtre de Kalman sans parfum quelques modifications doivent être opérées.

IV.4.1.1 Mouvement rectiligne à vitesse constante

L'état de base d'un mouvement rectiligne à vitesse constante est :

$$\begin{cases} s = (t_k - t_{k-1})\nu + s_0 \\ \nu = \frac{ds}{dt} = \dot{s} \end{cases} \quad (\text{IV.59})$$

Où

s : distance parcourue, ν : la vitesse et $(t_k - t_{k-1})$ est la différence du temps.

En discret, ces équations deviennent :

$$\begin{cases} s(k) = (t_k - t_{k-1})\nu(k-1) + s(k-1) \\ \nu(k) = \nu(k-1) \end{cases} \quad (\text{IV.60})$$

Posons $\begin{cases} x_1(k) = s(k) \\ x_2(k) = \nu(k) \end{cases}$ on obtient $x(k) = \begin{cases} x_1(k) = x_1(k-1) + T x_2(k-1) \\ x_2(k) = x_2(k-1) \end{cases}$ (IV.61)

avec $T = t_k - t_{k-1}$

L'équation du vecteur des paramètres de trajectoire est $\theta(k) = \begin{cases} \alpha \\ d \end{cases}$

Posons $\begin{cases} x_3(k) = \alpha \\ x_4(k) = d \end{cases}$ on obtient $\theta(k) = \begin{cases} x_3(k) = x_3(k-1) \\ x_4(k) = x_4(k-1) \end{cases}$ (IV.62)

Parce qu'ils sont invariants dans le temps, l'état augmenté sera :

$$X(k) = \begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix} = \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \\ x_4(k) \end{bmatrix}$$

$$X(k) = \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \\ x_4(k) \end{bmatrix} = \begin{bmatrix} x_1(k-1) + T x_2(k-1) \\ x_2(k-1) \\ x_3(k-1) \\ x_4(k-1) \end{bmatrix}$$

$$X(k) = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} X(k-1) \quad (\text{IV.63})$$

Sous la forme $X(k+1) = FX(k)$

Le modèle de mesure est une fonction non linéaire définie par :

$$\begin{cases} X = d \cos(\alpha) + s \sin(\alpha) \\ Y = d \sin(\alpha) - s \cos(\alpha) \end{cases} \quad (\text{IV.64})$$

Avec X et Y coordonnées cartésiennes de la cible.

Ces équations peuvent être écrites en fonction de variables d'état comme suit :

$$z(k) = \begin{cases} X(k) = x_4(k) \cos(x_3(k)) + x_1(k) \sin(x_3(k)) \\ Y(k) = x_4(k) \sin(x_3(k)) - x_1(k) \cos(x_3(k)) \end{cases} \quad (\text{IV-65})$$

de la forme $z(k) = h(X(k))$

IV.4.1.2 Mouvement rectiligne à accélération constante

L'état de base d'un mouvement rectiligne à accélération constante est :

$$\begin{cases} s(k) = s(k-1) + Tv(k-1) + \frac{1}{2}T^2a(k-1) \\ v(k) = v(k-1) + Ta(k-1) \\ a(k) = a(k-1) \end{cases} \quad (\text{IV-66})$$

L'équation du vecteur des paramètres reste la même que pour le mouvement rectiligne à vitesse constante.

Posons
$$\begin{cases} x_1(k) = s(k) \\ x_2(k) = v(k) \\ x_3(k) = a(k) \\ x_4(k) = \alpha \\ x_5(k) = d \end{cases}$$

L'état augmenté sera

$$X(k) = \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \\ x_4(k) \\ x_5(k) \end{bmatrix} = \begin{bmatrix} x_1(k-1) + Tx_2(k-1) + 0.5T^2x_3(k-1) \\ x_2(k-1) + Tx_3(k-1) \\ x_3(k-1) \\ x_4(k-1) \\ x_5(k-1) \end{bmatrix}$$

$$X(k) = \begin{bmatrix} 1 & T & 0.5T^2 & 0 & 0 \\ 0 & 1 & T & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} X(k-1) \quad (\text{IV.67})$$

De la forme $X(k+1) = FX(k)$

La fonction de mesure reste la même que pour le mouvement précédent, la seule différence se trouve dans l'ordre des variables d'état.

$$z(k) = \begin{cases} X(k) = x_5(k) \cos(x_4(k)) + x_1(k) \sin(x_4(k)) \\ Y(k) = x_5(k) \sin(x_4(k)) - x_1(k) \cos(x_4(k)) \end{cases} \quad (\text{IV.68})$$

IV.4.1.3 Mouvement circulaire à vitesse constante

L'état de base d'un mouvement circulaire à vitesse constante est identique de celui du mouvement rectiligne à vitesse constante, c'est-à-dire :

$$x(k) = \begin{cases} x_1(k) = x_1(k-1) + Tx_2(k-1) \\ x_2(k) = x_2(k-1) \end{cases} \quad (\text{IV.69})$$

L'équation du vecteur des paramètres est :

$$\theta(k) = \begin{bmatrix} R0 \\ X0 \\ Y0 \end{bmatrix} \quad (\text{IV.70})$$

Posons $\begin{bmatrix} x_3(k) = R0 \\ x_4(k) = X0 \\ x_5(k) = Y0 \end{bmatrix}$

L'état augmenté sera

$$X(k) = \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \\ x_4(k) \\ x_5(k) \end{bmatrix} = \begin{bmatrix} x_1(k-1) + Tx_2(k-1) \\ x_2(k-1) \\ x_3(k-1) \\ x_4(k-1) \\ x_5(k-1) \end{bmatrix}$$

$$X(k) = \begin{bmatrix} 1 & T & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} X(k-1) \quad (\text{IV.71})$$

de la forme $X(k+1) = FX(k)$

Les équations de mesure qui décrivent la position de l'objet poursuivi sont :

$$\begin{cases} X = X0 + R0 \cos\left(\frac{s}{R0}\right) \\ Y = Y0 + R0 \sin\left(\frac{s}{R0}\right) \end{cases} \quad (\text{IV.72})$$

Cette équation peut être écrite en fonction des variable d'état comme suit :

$$z(k) = \begin{cases} X(k) = x_4(k) + x_3(k) \cos\left(\frac{x_1(k)}{x_3(k)}\right) \\ Y(k) = x_5(k) + x_3(k) \sin\left(\frac{x_1(k)}{x_3(k)}\right) \end{cases} \quad (\text{IV.73})$$

De la forme $z(k) = h(X(k))$

IV.4.1.4 Mouvement circulaire à accélération constante

L'état de base d'un mouvement circulaire à accélération constante est identique de celui du mouvement rectiligne à accélération constante :

$$\begin{cases} s(k) = s(k-1) + Tv(k-1) + \frac{1}{2}T^2a(k-1) \\ v(k) = v(k-1) + Ta(k-1) \\ a(k) = a(k-1) \end{cases} \quad (\text{IV.74})$$

Le vecteur des paramètres de la trajectoire est :

$$\theta(k) = \begin{bmatrix} R0 \\ X0 \\ Y0 \end{bmatrix} \quad (\text{IV.75})$$

Posons

$$\begin{cases} x_1(k) = s(k) \\ x_2(k) = v(k) \\ x_3(k) = a(k) \\ x_4(k) = R0 \\ x_5(k) = X0 \\ x_6(k) = Y0 \end{cases}$$

L'état augmenté sera

$$X(k) = \begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix} = \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \\ x_4(k) \\ x_5(k) \\ x_6(k) \end{bmatrix}$$

$$X(k) = \begin{bmatrix} 1 & T & 0.5T^2 & 0 & 0 & 0 \\ 0 & 1 & T & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} X(k-1) \quad (IV.76)$$

de la forme

$$X(k+1) = FX(k)$$

Les équations de mesure sont les mêmes que celles du mouvement circulaire à vitesse constante :

$$z(k) = \begin{cases} X(k) = x_5(k) + x_4(k) \cos\left(\frac{x_1(k)}{x_4(k)}\right) \\ Y(k) = x_6(k) + x_4(k) \sin\left(\frac{x_1(k)}{x_4(k)}\right) \end{cases} \quad (IV.77)$$

IV.4.2 Simulation

Dans cette phase de simulation, nous allons mettre en évidence à la fois l'efficacité de notre algorithme **IMM-UKF** pour la poursuite de cible manoeuvrante et suivant des modèles de mouvements non linéaire, et sa supériorité par rapport à un algorithme IMM combiné avec le filtre de kalman étendu que nous avons noté **IMM-EKF**; en effet nous allons

confirmer à travers ces simulations toutes les limitations et appréhensions que nous avons à propos du filtre de kalman étendu.

Pour confirmer la robustesse de notre algorithme, nous avons considéré plusieurs scénarii de mouvements, de trajectoires et de manœuvres de la cible traquée, pour chaque scénario nous avons considéré 100 exécutions Monté carlo.

IV.4.2.1 Paramètres utilisés dans les algorithmes IMM-UKF et IMM-EKF

Pour les différentes simulations, nous avons considéré quatre (04) modèles de mouvements possibles pour la cible, à savoir :

1. Le modèle M_1 : Mouvement rectiligne à vitesse constante,
2. Le modèle M_2 : Mouvement rectiligne à accélération constante,
3. Le modèle M_3 : Mouvement circulaire à vitesse constante,
4. Le modèle M_4 : Mouvement circulaire à accélération constante.

Le vecteur d'état de chaque filtre est de dimension $n=8$, ces états sont définis comme suit :

$$\left\{ \begin{array}{l} x_1(k) = s(k) \quad \text{distance parcourue de la cible.} \\ x_2(k) = v(k) \quad \text{vitesse de la cible.} \\ x_3(k) = \gamma(k) \quad \text{accélération de la cible.} \\ x_4(k) = \alpha \quad \text{angle de trajectoire rectiligne} \\ x_5(k) = d \quad \text{distance perpendiculaire entre la trajectoire rectiligne et} \\ \quad \text{l'origine du repère.} \\ x_6(k) = R0 \quad \text{rayon de la trajectoire} \\ \dots \\ \left. \begin{array}{l} x_7(k) = X0 \\ x_8(k) = Y0 \end{array} \right\} \quad \text{Coordonnées du centre de cette trajectoire curviligne.} \end{array} \right.$$

Les quatre filtres sont initialisés avec les conditions suivantes :

- ✓ Le bruit de processus, est un bruit blanc additif de moyenne nulle, indépendant du bruit de mesure et de covariance $\sigma_v^2=0.01$,
- ✓ Le bruit de processus, est un bruit blanc additif de moyenne nulle, indépendant du bruit de mesure et de covariance $\sigma_w^2=0.001$,
- ✓ Le vecteur de probabilités initiales des modèles est :

$$\mu(0) = \begin{bmatrix} 0.25 \\ 0.25 \\ 0.25 \\ 0.25 \end{bmatrix}$$

Les 04 modèles sont considérés équiprobables à l'instant initial.

- ✓ Les probabilités de transition de la chaîne de Markov gouvernant le changement (switching) entre les 4 modèles dans les algorithmes IMM-UKF et IMM-FKE sont choisies comme suit pour tous les scénarii:

$$p_{ij} = \begin{bmatrix} 0.997 & 0.001 & 0.001 & 0.001 \\ 0.001 & 0.997 & 0.001 & 0.001 \\ 0.001 & 0.001 & 0.997 & 0.001 \\ 0.001 & 0.001 & 0.001 & 0.997 \end{bmatrix}$$

Ces probabilités de transition sont constantes et invariables dans le temps, étant donné que nous avons considéré une chaîne de Markov homogène.

- ✓ La mesure $z(k)$ de la position 2-D de la cible est supposée acquise par un capteur de vision (caméra).
- ✓ Tous les filtres sont initialisés par le vecteur d'état suivant :

$$X = [s, \dot{s}, \ddot{s}, \alpha, d, R, 0, x_0, y_0]$$

$$X(0) = [1m \ 1m/s \ 0.1m/s^2 \ 1rad \ 50m \ 90m \ -30m \ 40m]$$


IV.4.2.2 Scénarii

a. Scénario 1

La cible se déplace selon le modèle M_1 , jusqu'à l'instant $k=50$ où une brusque accélération, d'amplitude 0.2m/s^2 , apparaît et se maintient durant les 50 échantillons suivants. (La cible bascule du modèle M_1 au modèle M_2).

Paramètres de la trajectoire :


Pour M_1 et M_2 : $\alpha = 60$ degrés = 1.04 radians, $d = 80$ m.



a) IMM-UKF

b) IMM-EKF

Figure (IV.3): Trajectoire réelle et estimée



a) IMM-UKF

b) IMM-EKF

Figure (IV.4): Probabilités des modèles




Figure (IV.5) : Erreur quadratique moyenne des positions en x et y




Figure (IV.6) : Erreur quadratique moyenne de la vitesse et d'accélération




Figure (IV.7) : Erreur quadratique moyenne des paramètres de la trajectoire

b. Scénario 2

La cible se déplace selon le modèle M₃, jusqu'à l'instant k=50 où une accélération abrupte d'amplitude 0.2 m/s² survient et reste effective durant les 50 échantillons suivants (la cible bascule du modèle M₃ au modèle M₄).

Paramètres de la trajectoire :

Pour M₃ et M₄ : R₀=100 m, x₀=-26 m, y₀= 50 m.




Figure (IV.8): Trajectoire réelle et estimée




Figure (IV.9): Probabilités des modèles




Figure (IV.10) : Erreur quadratique moyenne des positions en x et y




Figure (IV.11) : Erreur quadratique moyenne de la vitesse et d'accélération




Figure (IV.12) : Erreur quadratique moyenne des paramètres de la trajectoire

c. Scénario 3

La cible se déplace selon le modèle M_1 , jusqu'à l'instant $k=50$ où la cible change brusquement de trajectoire en passant d'une trajectoire rectiligne à une autre circulaire et continue sur cette dernière durant les 50 échantillons suivants (la cible bascule du modèle M_1 au modèle M_3).

Paramètres des trajectoires :

Pour M_1 : $\alpha = 90$ degrés = 1.47 radians, $d = 60$ m.

Pour M_3 : $R_0 = 80$ m, $x_0 = -52$ m, $y_0 = 36$ m.




Figure (IV.13): Trajectoire réelle et estimée




Figure (IV.14): Probabilités des modèles




Figure (IV.15) : Erreur quadratique moyenne des positions en x et y




Figure (IV.16) : Erreur quadratique moyenne de la vitesse

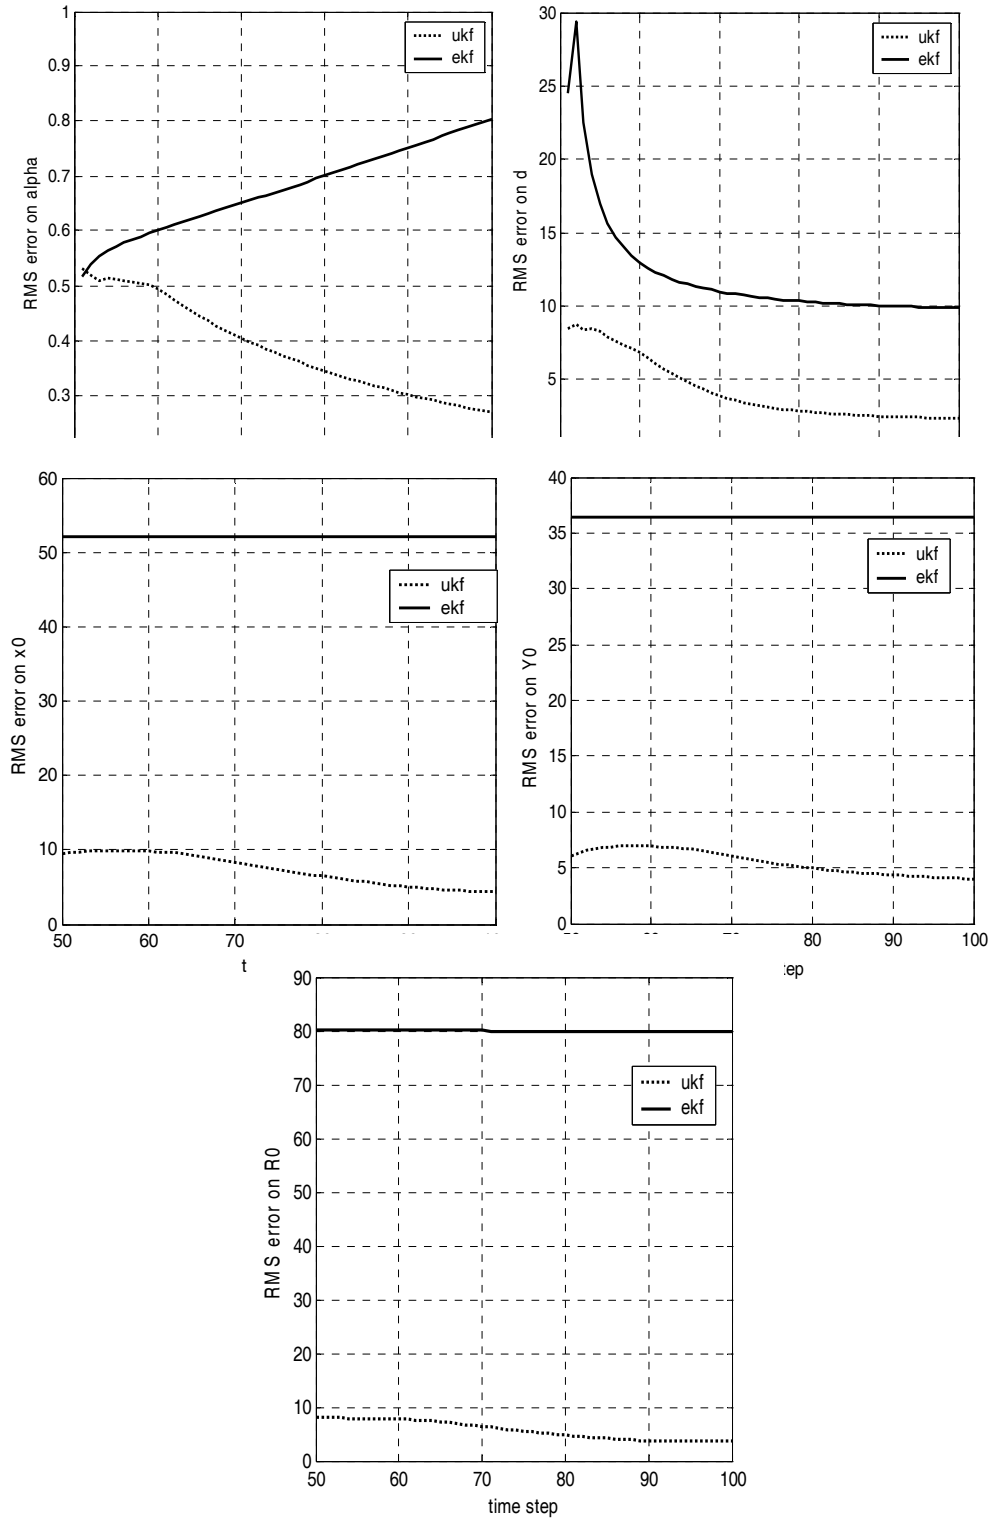


Figure (IV.17) : Erreur quadratique moyenne des paramètres des trajectoires

d. Scénario 4

La cible se déplace selon le modèle M1, jusqu'à l'instant $k=50$ où un brusque saut d'accélération d'amplitude 0.2 m/s² apparaît, et au même temps un changement au niveau de la trajectoire qui passe de la rectiligne à la circulaire, ce scénario se maintient durant les 50 échantillons suivants (la cible bascule du modèle M1 au modèle M4).

Paramètres des trajectoires :

Pour M₁ : $\alpha = 90$ degrés = 1.47 radians, $d = 100$ m.

Pour M₃ : $R_0 = 100$ m, $x_0 = -39$ m, $y_0 = 53$ m.




Figure (IV.18): Trajectoire réelle et estimée




Figure (IV.19): Probabilités des modèles




Figure (IV.20) : Erreur quadratique moyenne des positions en x et y


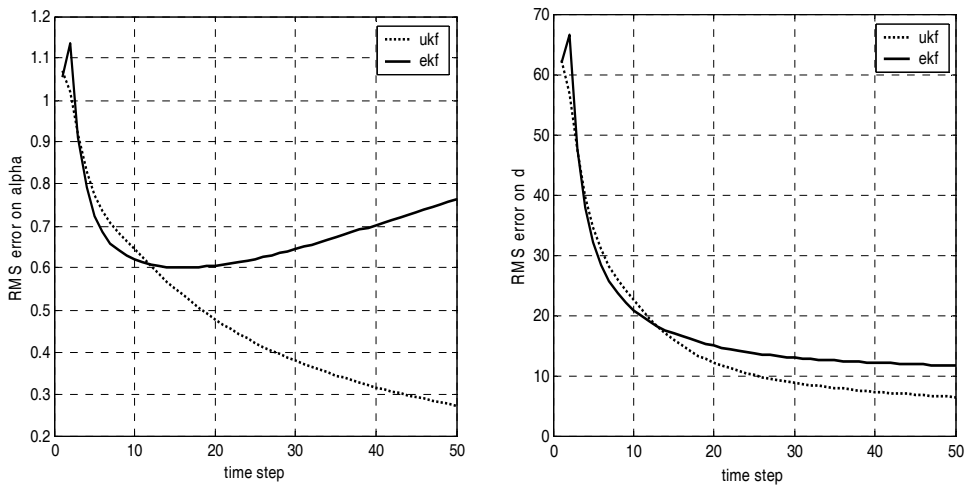


Figure (IV.21) : Erreur quadratique moyenne de la vitesse et d'accélération



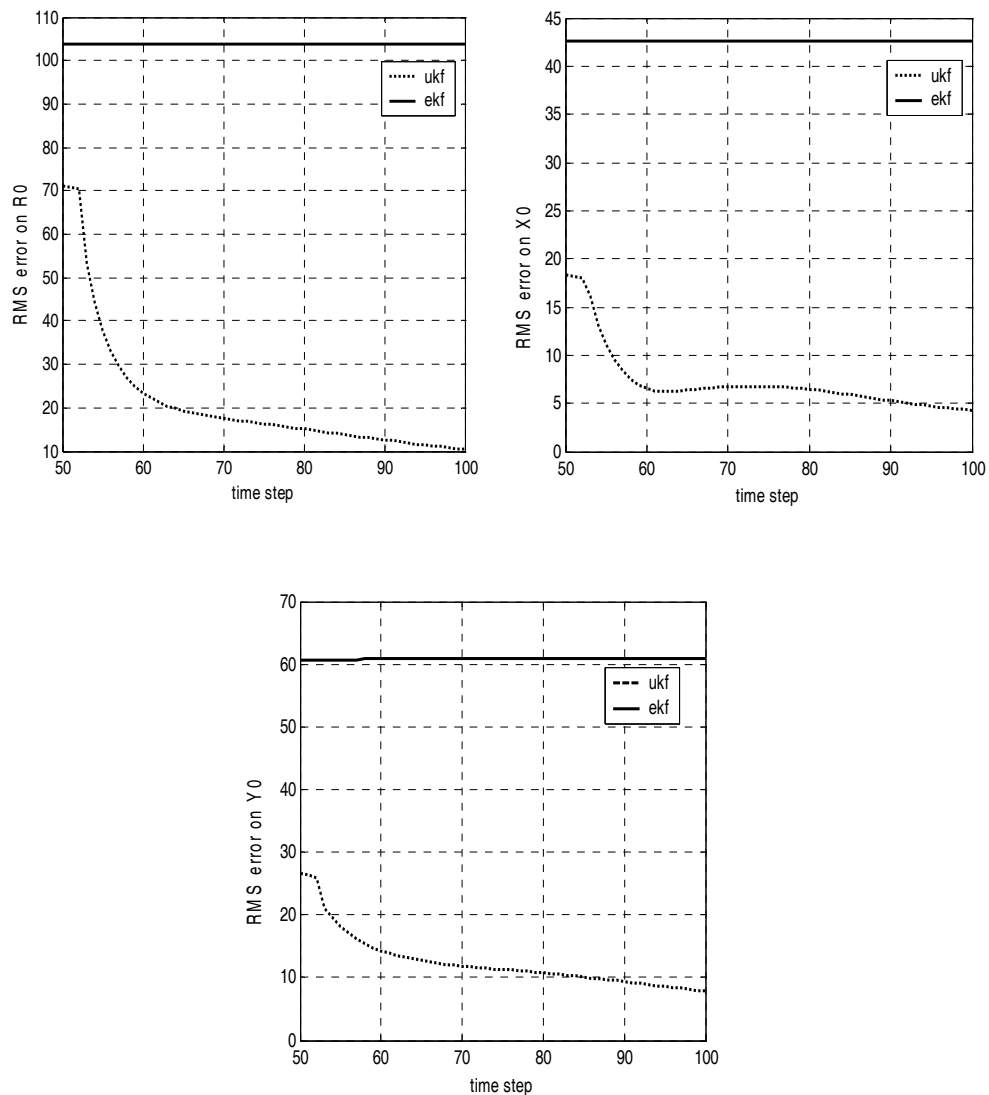


Figure (IV.22) : Erreur quadratique moyenne des paramètres des trajectoires

e. Scénario 5


La cible se déplace selon le modèle M_1 , jusqu'à l'instant $k=50$ où un brusque changement de trajectoire survient, la cible passe d'une trajectoire rectiligne à une trajectoire circulaire, et maintient celle-ci jusqu'à l'instant $k=100$ où un second saut se produit, en effet à cet instant il y a apparition d'une brusque accélération d'amplitude 0.2 m/s^2 (la cible bascule du modèle M_1 au modèle M_3 ensuite de ce dernier vers le modèle M_4).

Paramètres des trajectoires :


Pour M_1 : $\alpha = 60$ degrés = 1.04 radians, $d = 100 \text{ m}$

Pour M_3 : $R_0 = 100 \text{ m}$, $x_0 = -26 \text{ m}$, $y_0 = 50 \text{ m}$

Pour M_4 : $R_0 = 120 \text{ m}$, $x_0 = -48 \text{ m}$, $y_0 = 51 \text{ m}$.




a) IMM-UKF




b) IMM-EKF

Figure (IV.23): Trajectoire réelle et estimée



a) IMM-UKF



b) IMM-EKF

Figure (IV.24): Probabilités des modèles




Figure (IV.25) : Erreur quadratique moyenne des positions en x et y




Figure (IV.26) : Erreur quadratique moyenne de la vitesse et de l'accélération

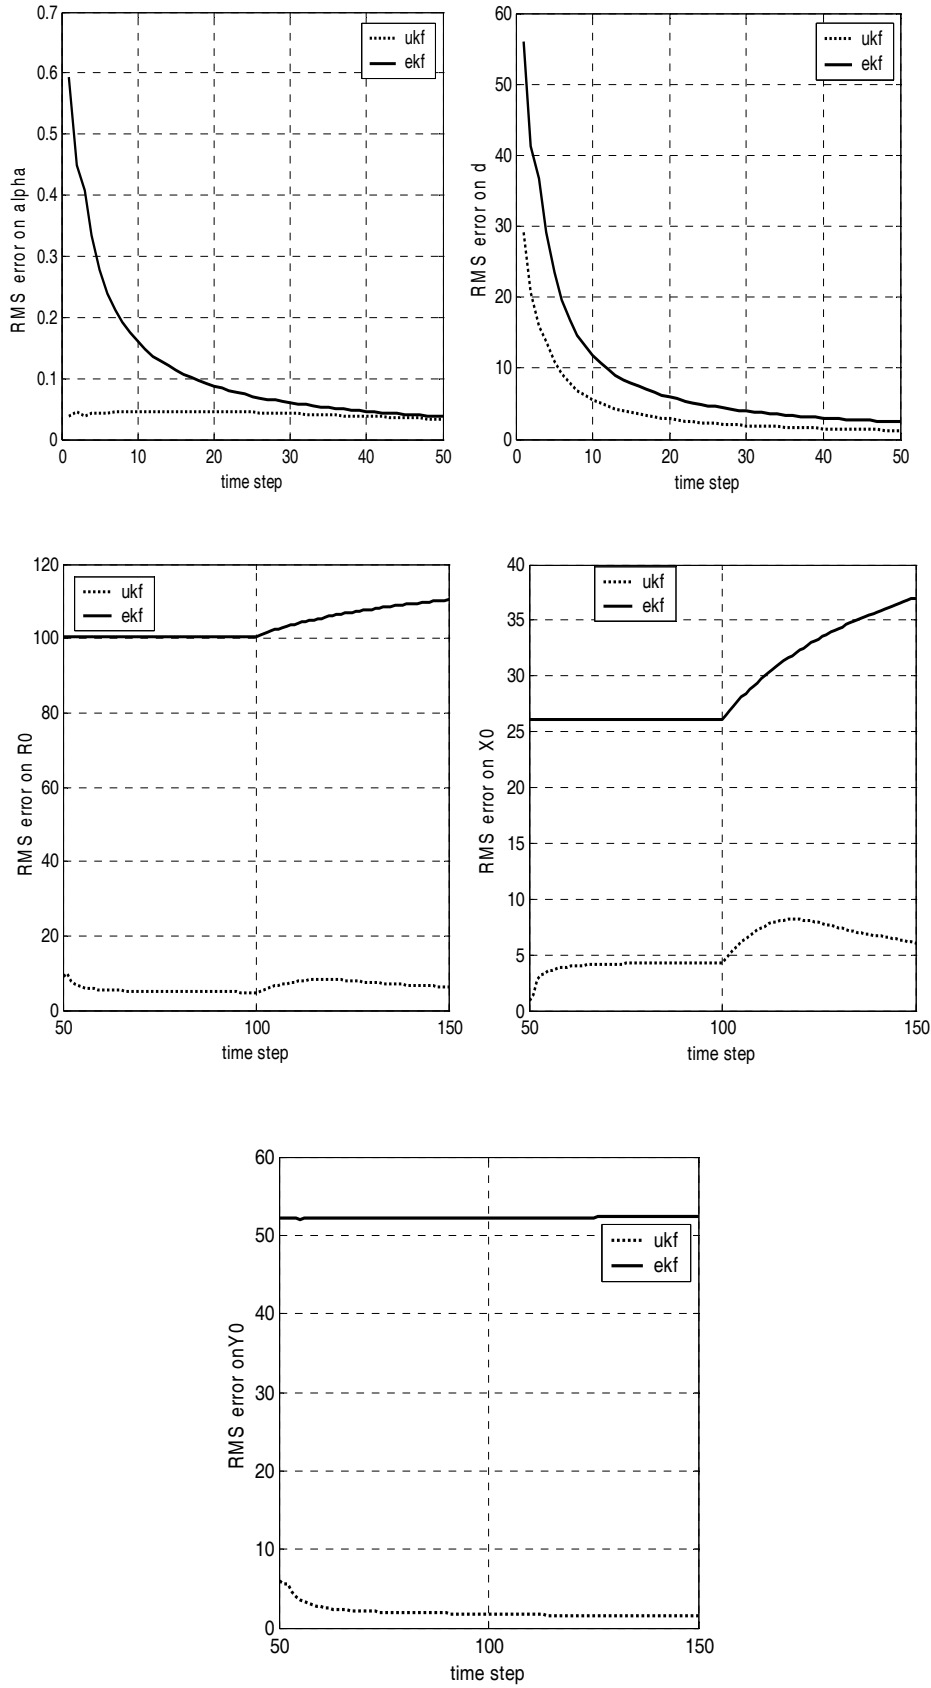


Figure (IV.27) : Erreur quadratique moyenne des paramètres des trajectoires

IV.4.2.3 Interprétation des résultats

Scénario 1 :

La figure (IV.3) montre que les trajectoires réelle et estimée sont superposables et pratiquement identiques pour les deux algorithmes IMM-UKF et IMM-EKF, malgré l'apparition abrupte d'un changement au niveau de la dynamique du mouvement de la cible traquée. Cependant, comme nous pouvons le constater sur la figure (IV.4), l'algorithme IMM-UKF détecte ce brusque changement au niveau de la dynamique de la cible plus vite que l'algorithme IMM-EKF. Mis à part cela, et vue les figures (IV.5), (IV.6) et IV.7), les deux algorithmes convergent vers les bonnes positions de la cible, vers les bons paramètres des trajectoires et enfin vers les bonnes valeurs de vitesse et d'accélération.

Scénario 2 :

Comme dans le premier scénario, la figure (IV.8) montre que les trajectoires réelle et estimée sont superposables et pratiquement identiques pour les deux algorithmes IMM-UKF et IMM-EKF, malgré l'apparition brusque d'un saut au niveau de la dynamique de la cible (figure (IV.9)). Après la détection du dit saut, les deux algorithmes convergent vers les bonnes positions de la cible, vers les bons paramètres de trajectoires et enfin vers les bonnes valeurs de la vitesse et de l'accélération.

Scénario 3 :

La figure (IV.13), montre qu'avant le changement brusque, de la nature de la trajectoire, les deux algorithmes convergent vers la bonne trajectoire. Cependant après le saut, seul l'IMM-UKF détecte et converge vers la nouvelle trajectoire. Ce résultat est confirmé par la figure (IV.14) qui montre la bonne transition de l'algorithme IMM-UKF du modèle M_1 vers le modèle M_3 , et l'incapacité de l'algorithme IMM-EKF à converger vers la bonne trajectoire après la brusque rupture de cette dernière. Les figures (IV.15), (IV.16) et (IV.17) confirment davantage ce constat; en effet, seul l'algorithme IMM-UKF converge vers la bonne position de la cible, vers les bons paramètres de trajectoires et vers la bonne dynamique de la cible après la manoeuvre, l'algorithme IMM-EKF quant à lui, diverge complètement.

Scénario 4 :

Comme dans le cas du troisième scénario, la figure (IV.18) montre qu'avant le brusque changement de trajectoire et de la dynamique de la cible, les deux algorithmes convergent vers la bonne trajectoire. Cependant après le brusque changement, seul l'IMM-UKF converge vers la nouvelle trajectoire. Ceci est confirmé par la figure (IV.19) qui montre la bonne transition de l'algorithme IMM-UKF du modèle M_1 vers le modèle M_2 , et l'incapacité de l'IMM-EKF de converger vers le bon modèle après le brusque changement. Les figures (IV.20), (IV.21) et (IV.22) confirment également cette

remarque, comme nous pouvons remarquer, seul l'IMM-UKF converge vers les bonnes positions de la cible, vers les bons paramètres de trajectoires et vers la bonne dynamique de la cible; l'IMM-EKF quant à lui diverge complètement.

Scénario 5 :

Comme dans le cas du troisième et quatrième scénario, la figure (IV.23) montre qu'avant le premier saut brusque au niveau de la trajectoire, les deux algorithmes convergent vers la bonne trajectoire suivie par la cible. Cependant, après l'abrupt changement de cette dernière, seul l'IMM - UKF détecte et converge vers la nouvelle trajectoire. Le second saut est également détecté par l'algorithme IMM-UKF et converge vers la bonne trajectoire, par contre l'IMM-EKF continue à être complètement divergent. Ce constat, est également confirmé par la figure (IV.24) qui montre la bonne transition de l'algorithme IMM-UKF du modèle M_1 vers le modèle M_3 et ensuite du modèle M_3 vers le modèle M_4 , et l'incapacité de l'IMM-EKF de suivre de telles manoeuvres. Les figures (IV.25), (IV.26) et (IV.27) confirment également ce résultat; en effet, comme il est possible de voir, seul l'algorithme IMM-UKF converge vers les bonnes positions de la cible, vers les bons paramètres de trajectoires et vers la bonne dynamique de la cible après la manoeuvre, l'algorithme IMM-EKF quant à lui diverge complètement.

IV.5 Conclusion

A partir des ces différents scénarii, nous pouvons affirmer que l'utilisation de l'algorithme IMM-EKF peut être envisagée pour assurer la poursuite d'une cible, dont la dynamique peut changer d'une manière sporadique durant son mouvement, tout en maintenant la même trajectoire (simple accélération le long de la même trajectoire). Cependant, lorsque nous sommes amenés à traquer une cible fortement manoeuvrante, dont la dynamique et/ou la nature de sa trajectoire est amenée à changer brusquement dans le temps; et lorsque les modèles de processus et/ou de mesure sont fortement non linéaires, seul l'algorithme IMM-UKF peut être envisagé pour assurer une bonne poursuite de la dite cible. De là, nous pouvons affirmer que l'algorithme que nous avons mis en œuvre l'IMM-UKF constitue une solution pertinente au problème de la poursuite de cibles fortement manoeuvrantes.

Conclusion et Perspectives

La vision est devenue un organe essentiel dans un système robotique. Cette vision, dite artificielle, va lui permettre d'accomplir des tâches nouvelles, plus complexes. Un robot sera alors capable de se " rendre compte" de l'environnement qui l'entoure. L'utilisation d'informations visuelles va inévitablement rendre la commande des robots plus complexe. De nouvelles techniques ont dû alors être mises au point, pour répondre au mieux à ces problèmes. L'approche qui permet d'utiliser ces informations est l'asservissement visuel.

Après avoir présenté un bref état de l'art de l'asservissement visuel, afin de pouvoir situer ce présent travail dans ce domaine en pleine expansion, nous avons proposé et présenté une première approche de résolution du problème de poursuite de cibles manoeuvrantes. Cette dernière est basée sur le *test d'hypothèse* qui consiste à émettre l'hypothèse qu'un saut au niveau d'une composante du vecteur d'état, c'est opérer à un instant passé θ , qu'il faudra estimer ainsi que l'amplitude de ce saut pour corriger les prédictions et estimées futures, afin d'assurer la convergence du filtre de poursuite. Ceci pour la première hypothèse, la seconde hypothèse quant à elle, consiste à dire que rien de tout cela n'est vrai et qu'il n'y a eu aucun saut au cours des instants passés. Pour décider de la pertinence de l'une ou l'autre des deux hypothèses, nous avons opté pour le test du maximum de vraisemblance généralisé (GLR). Des essais et tests de simulation ont montré la pertinence de cette approche.

Comme seconde approche, nous avons considéré le cas, plus complexe, de cibles manoeuvrantes dont les modèles de mesures et/ou de processus sont non linéaires. Comme solution à ce problème, nous avons proposé une extension de l'algorithme IMM, dédié aux modèles linéaires, au cas de modèles non linéaires. Le premier algorithme mis en œuvre, est l'IMM-EKF, qui est le résultat d'une combinaison de l'IMM standard et du filtre de kalman étendu (EKF), les résultats donnés par cet algorithme, sont satisfaisants, néanmoins il reste restreint au cas de cibles faiblement manoeuvrantes (saut uniquement au niveau de la dynamique, sans changer de trajectoire). Pour remédier à cette limitation et pour généraliser le dit algorithme au cas de cibles fortement manoeuvrantes (sauts brusques au niveau de la dynamique et de la trajectoire de la cible), nous avons mis en œuvre une autre variante de l'algorithme, à savoir l'IMM-UKF. Ce dernier résulte de la combinaison de l'algorithme IMM de base avec le filtre de kalman sans parfum (UKF).

Pour monter l'opportunité et l'efficacité, pour la poursuite de cibles fortement manoeuvrantes, de ce nouvel algorithme (IMM-UKF), nous avons procédé à des tests Monté Carlo, ce en considérant plusieurs scénarii possibles pour la cible. Malgré la complexité de ces derniers, l'algorithme que nous avons mis en œuvre, a confirmé son efficacité en convergeant à tout les coups vers les bonnes trajectoires suivies par la cibles malgré les fortes non

linéarités des modèles choisis. Ces résultats nous amènent donc à affirmer que nous avons mis en œuvre un algorithme capable de poursuivre toute cible, quelque soient ses manœuvres et quelque soient les non linéarités des modèles de mouvement subis.

Enfin, pour conclure, plusieurs perspectives intéressantes peuvent être envisagées à ce présent travail, à savoir :

- ✓ Validation des présents résultats sur une plateforme expérimentale physique réelle,
- ✓ Tester d'autres filtres autre que le filtre de Kalman sans parfum afin d'étendre l'algorithme aux cas de distributions quelconques autre que gaussienne, tel que le filtre à particules,
- ✓ Etendre cette approche à la poursuite multicibles,
- ✓ Envisager le cas d'apparition du phénomène du fading et/ou de mesures erronées.

Annexe A

Equations du filtre de Kalman étendu (EKF)

Soit le système défini par les équations suivantes :

$$x(k+1) = \mathfrak{R}(x(k), k) + u(k) + v(k)$$

$$z(k) = \wp(x(k), k) + w(k)$$

Les équations du filtre de Kalman étendu correspondant sont:

$$\hat{x}(k+1/k+1) = \hat{x}(k+1/k) + K(k+1)[z(k+1) - \wp(\hat{x}(k+1/k), k+1)]$$

$$\hat{x}(k+1/k) = \mathfrak{R}(\hat{x}(k/k), k) + u(k)$$

$$K(k+1) = P(k+1/k)H^T(k+1)(H(k+1)P(k+1/k)H^T(k+1) + R(k+1))^{-1}$$

$$P(k+1/k+1) = (I - K(k+1)H(k+1))P(k+1/k)$$

$$P(k+1/k) = \Phi(k)P(k/k)\Phi^T(k) + Q(k)$$

$$\Phi(k) = \left. \frac{\partial \mathfrak{R}(x(k), k)}{\partial x(k)} \right|_{x(k)=\hat{x}(k/k)}$$

$$H(k+1) = \left. \frac{\partial \wp(x(k+1), k+1)}{\partial x(k+1)} \right|_{x(k+1)=\hat{x}(k+1/k)}$$

Annexe B

Algorithme IMM

Un cycle de l'algorithme se déroule selon les étapes suivantes :

1. Calcul de probabilités mixtes

La probabilité que le mode M_i était en effet à l'instant $k-1$ étant donnée que M_j est en effet à l'instant k conditionnée sur Z^{k-1} est

$$\begin{aligned}\mu_{i|j}(k-1/k-1) &= P\{M_i(k-1)|M_j(k), Z^{k-1}\} \\ &= \frac{1}{\bar{c}_j} P\{M_j(k)|M_i(k-1), Z^{k-1}\} P\{M_i(k-1)|Z^{k-1}\}\end{aligned}\quad (1)$$

les probabilités mixtes ce-dessus qui peuvent être écrites comme suit :

$$\mu_{i|j}(k-1/k-1) = \frac{1}{\bar{c}_j} p_{ij} \mu_i(k-1) \quad i, j = 1, \dots, r \quad (2)$$

où les constantes de normalisation sont:

$$\bar{c}_j = \sum_{i=1}^r p_{ij} \mu_i(k-1) \quad j = 1, \dots, r \quad (3)$$

2. Mixage

Commençant avec $\hat{x}_i(k-1|k-1)$, on calcule l'état initial mixé pour le filtre correspondant à $M_j(k)$ selon :

$$\hat{x}^j(k-1/k-1) = \sum_{i=1}^r \hat{x}_i(k-1/k-1) \mu_{i|j}(k-1/k-1) \quad j = 1, \dots, r \quad (4)$$

et sa covariance selon:

$$\begin{aligned}P^j(k-1/k-1) &= \sum_{i=1}^r \mu_{i|j}(k-1/k-1) \left\{ P_i(k-1/k-1) + \right. \\ &\quad \left. \left[\hat{x}_i(k-1/k-1) - x^j(k-1/k-1) \right] \left[\hat{x}_i(k-1/k-1) - x^j(k-1/k-1) \right]^T \right\}\end{aligned}\quad (5)$$

3. Filtrage

Les estimées et covariances obtenues par les équations (4) et (5) sont utilisées comme des entrées du filtre correspondant à $M_j(k)$, qui utilise $z(k)$ pour donner $\hat{x}_j(k|k)$ et $P_j(k|k)$.

Les fonctions de vraisemblance (likelihood functions) correspondant aux r filtres sont :

$$\Lambda_j(k) = N\left\{x(k); \hat{z}_j\left\{k|k-1; \hat{x}^j(k-1|k-1)\right\}, S_j\left\{k; P^j(k-1|k-1)\right\}\right\} \quad (6)$$

4. Mise à jour de probabilité

Cela se fait comme suit:

$$\begin{aligned} \mu_j(k) &= P\left\{M_j(k) \mid Z^k\right\} \\ &= \frac{1}{c} f\left\{z(k) \mid M_j(k), Z^{k-1}\right\} P\left\{M_j(k) \mid Z^{k-1}\right\} \\ &= \frac{1}{c} \Lambda_j(k) \sum_{i=1}^r P\left\{M_j(k) \mid M_i(k-1), Z^{k-1}\right\} P\left\{M_i(k-1) \mid Z^{k-1}\right\} \\ &= \frac{1}{c} \Lambda_j(k) \sum_{i=1}^r p_{ij} \mu_i(k-1) \quad j = 1, \dots, r \end{aligned} \quad (7)$$

avec

$$\mu_j(k) = \frac{1}{c} \Lambda_j(k) \bar{c}_j \quad j = 1, \dots, r \quad (8)$$

$$c = \sum_{j=1}^r \Lambda_j(k) \bar{c}_j \quad (9)$$

5. Combinaison d'états estimés et covariances

La combinaison des estimations de modèles conditionnés et covariances est faite selon les équations de mixture :

$$\hat{x}(k/k) = \sum_{j=1}^r x_j(k|k) \mu_j(k) \quad (10)$$

$$P(k/k) = \sum_{j=1}^r \mu_j(k) \left\{ P_j(k|k) + \left[\hat{x}_j(k|k) - \hat{x}(k|k) \right] \left[\hat{x}_j(k|k) - \hat{x}(k|k) \right]^T \right\} \quad (11)$$

Cette combinaison est seulement pour les buts de sortie, ce n'est pas une partie des récursions de l'algorithme.

Bibliographie

- [1] M. A. Isard, "Visual Motion Analysis by Probabilistic Propagation of Conditional density," *PHD Thesis*, Cambridge University, September 1998.
- [2] V.J. Aidala, and S.E. Hammel, "Utilization of modified polar coordinates for bearing-only tracking," *In H.W. Sorenson, editor, Kalman Filtering: Theory and Application*, pages 291-302, IEEE Press, 1985.
- [3] P.K. Allen, A. Timcenko, B. Yoshimi, and P. Michelman, "Automated Tracking and Grasping of a Moving Object with a Robotic Hand-Eye System," *Technical report, CUCS-034-91*, Columbia University.
- [4] Y. Bar-Shalom, and X. Rong Li, "Estimation and Tracking: Principles," *Techniques and Software*. Norwood, MA: Artech House, 1993.
- [5] Y. Bar-Shalom, and T.E. Fortman, "Tracking and Data Association," *Mathematics in Science and Engineering*, volume 179, Academic Press, 1988.
- [6] M. Basseville, "Detecting Changes in Signals and Systems: A survey," *Automatica*, Vol.24, N°3, pp.309-326, 1988.
- [7] F. Bensalah, "Estimation de mouvement par vision active," *Thèse de doctorat, Université de RENNES 1*, 1996.
- [8] F. Bensalah, and F. Chaumette, "Target tracking by visual servoing using the generalized likelihood ratio test," *ICIA 95*, Nancy, 7-9 Juin 1995.
- [9] D.F. Bizup, "A Generalized Acceleration Model for Kalman Filter Trackers," *Proceedings IEEE*, 2004.
- [10] S. Blackman, "Multiple-Target Tracking with Radar Applications." Norwood, MA: Artech House, 1986.
- [11] S. Blackman, "Multiple Hypothesis Tracking for Multiple Target tracking," *IEEE A&E Systems magazine*, Vol.19, N°1, January 2004.
- [12] H.A.P. Blom, A.P. Henk, 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).
- [13] V. Broman, J. Shensa, "Polytope, a novel approach to tracking," *Proceedings of the 28th Conference on Decision and Control*, Athens, Greece, December 1986.

- [14] V. Cadenat, R. Swain, P. Soueres, and M. Devy, "A controller to perform a visually guided tracking task in a cluttered environment," *LAAS report 99012*, February 1999.
- [15] F. Chaumette, F. Bensalah, "Compensation of Abrupt motion Changes in target tracking by visual servoing," *IEEE/RSJ Int Conf on Intelligent Robots and Systems, IROS'95*. 1995.
- [16] F. Chaumette, A. Santos, "Tracking a moving object by visual servoing," *IRISA research report*.
- [17] F. Chaumette, "La relation vision-commande: théorie et application à des tâches robotiques," *thèse, Rennes 1, IRISA, Rennes*, 1990.
- [18] F. Chaumette, P. Rives and B. Espiau, "Positioning of a robot with respect to an object, tracking it and estimating its velocity by visual servoing," *In Proceedings of the 1991 IEEE International Conference on Robotics and Automation, volume 3, pages 2248-2253*, Sacramento, California, April 1991.
- [19] G. Chen, "Approximate Kalman filtering," *series in Approximations & Decompositions C. K. Chui, ed., World Scientific Publishing Singapore/ New Jersey*, 240. 1993.
- [20] B. Chen, and J.K. Tugnait, "Interacting Multiple Model Fixed-Lag Smoothing Algorithm For Markovian Switching Systems," *IEEE transactions on Aerospace and Electronic Systems, Vol.36, N°1*, January 2000.
- [21] P.I. Corke, "Visual control of robot manipulators," – *A Review. In K. Hashimoto (Ed.), Visual Servoing (Vol. 7, pp. 1-31)*. Singapore: World scientific. 1993
- [22] F.Campillo and F. Legland, "Threshold Selection in the GLRT for Change Detection in Partially Observed Diffusion Processes,".
- [23] F.Campillo and F. Legland, "Likelihood Based Statistics for Partially Observed Diffusion Processes,".
- [24] P.Danes, **M.S. Djouadi**, D. Bellot, "A 2-D Point-Wise Motion Estimation Scheme for Visual-Based Robotic Tasks," *7th International Symposium on Intelligent Robotic Systems (SIRS'99)*, Coimbra (Portugal), 20-23 July 1999, pp.119-128.
- [25] **M.S. Djouadi**, A. Sebbagh, and D. Berkani, "IMM-UKF and IMM-EKF Algorithms for Tracking Highly Maneuvring Target," *Archive of Contrôle Sciences, Vol:1, issue: 1*, 2005.

- [26] **M.S. Djouadi**, A. Sebbagh, and D. Berkani, "A Nonlinear Algorithm for Maneuvring Target Visual-Based Tracking," *ICISIP'05*, Chennai India, 4-7 Jan 2005.
- [27] **M.S. Djouadi**, A. Sebbagh, and D. Berkani, "IMM based UKF and IMM based EKF: A comparison", *WSEAS'05* Prague, Tcheque Republic, 13-15 Mach 2005.
- [28] **M.S. Djouadi**, A. Sebbagh, and D. Berkani, "Towards an Nonlinear Algorithm for Tracking Highly Maneuvring Target," *CGE'04*, 12-13 Avr 2005, Bordj el Bahri, EMP.
- [29] **M.S. Djouadi**, A. Sebbagh, and D. Berkani, "A Nonlinear Algorithm for Tracking Highly Maneuvring Target", *Arabian Journal of Sciences and Enginneering*, preliminary acceptance for publication on 2006.
- [30] **M.S. Djouadi**, Y. Morcely, H. Gessas, N. Ouadeh, "Saisie d'objets par asservissement visuel d'un bras manipulateur", *CGE'03*, 15-16 F ev 2004, Bordj el Bahri, EMP.
- [31] C. Doignon, G. Abba, and E. Ostertag, "Recognition and localization of solid objects by monocular vision system for robotic tasks," *IROS'94*, Munich, septembre 1994.
- [32] C. Doignon, N. Werghi, G. Abba, and E. Ostertag, "Reconnaissance et localisation d'objets en robotique par un syst eme de vision monoculaire," *ICIA'95*, PP. 511-516, Nancy, Juin 1995.
- [33] F. Dornaika, "Contribution   l'int egration vision/robotique : calibration, localisation, asservissement", *Th ese de l'INPG*, Grenoble, septembre 1995.
- [34] B. Espiau, F. Chaumette, and P. Rives, " A new approach to visual servoing in robotics," *IEEE Transactions on Robotics and Automation*, 8(3): 313-326, June 1992.
- [35] P. Fearnhead, "Sequential Monte-Carlo Methods in Filter Theory," *PHD Thesis*, Oxford University, 1998.
- [36] J. T. Feddema, C. S. G. Lee, "Adaptive image feature prediction and control for visual tracking with a hand-eye coordinated camera," *IEEE Trans. On Systems Man, and Cybernetics*, vol. 20, n o 5, pp.1172-1183, Octobre 1990.
- [37] R.A. Fisher, " On an absolute criterion for fitting frequency curves", *Messenger of Math*, 41,155. 1912.
- [38] T. Fukuda, R. Michelini, V. Potkonjak, S. Tzafestas, K. Valavanis, and M. Vukobratovic, "How Far Away is "Artificial Man", " *Robotics and Automation Magazine*, 7(1), pp. 66-73, 2001.

- [39] F. Gustafsson, "A two-filter off-line solution to optimal detection," *research report*, Linköping University, Sweden 1991.
- [40] F. Gustafsson, "Asymptotic Power and the Gain of Under-Modeling in Change Detection," *research report*, Linköping University, Sweden.
- [41] F. Gustafsson, "The marginalized likelihood ratio test for detecting abrupt changes", *IEEE transactions on Automatic Control*, Vol.41, N°1, January 1996.
- [42] J. Gangloff, "Asservissements visuels rapides d'un robot manipulateur à 6 degré de liberté," *Thèse de doctorat, Université de Louis Pasteur (université de Strasbourg)*, 1999.
- [43] A. Gelb, "Applied Optimal Estimation," *the MIT Press*, Cambridge 1974.
- [44] G. Hager, "Real-time feature tracking and projective invariance as a basis for hand-eye coordination," *Proc. of CVPR'94*, pp. 533-539, Seattle, USA, Juin 1994.
- [45] K. Hashimoto, and H. Kimura, "LQ Optimal and Nonlinear Approaches to Visual Servoing," *edited. by Hashimoto. K, pp. 165-198. World Scientific Series in Robotics and Automated Systems, vol. 7, World Scientific Press, Singapore*, 1993.
- [46] R.E. Helmick, W. Dale Blair, and S.A. Hoffman, "Fixed-Interval Smoothing for Markovian Switching Systems," *IEEE transactions on Information Theory*, Vol.41, N°6, November 1995.
- [47] R.E. Helmick, W. Dale Blair, S.A. and Hoffman, "One-Step Fixed-Lag Smoothers for Markovian Switching Systems," *IEEE Transactions on Automatic Control*. Vol.41. N°7, July 1996.
- [48] F. Hou, and F. Zhu, "Filter Algorithm for Visual Tracking of Maneuvring Target," *Proceedings IEEE* 2004.
- [49] S. Hutchinson, G.D. Hager, and P.I. Corke, "A tutorial on visual servo control," *IEEE Transactions on Robotics and Automation*, 12(5):651-670, October 1996.
- [50] J.L. Williams, "Flight Lieutenant, RAAF: Gaussian Mixture Reduction for Tracking Multiple Maneuvering Targets in Clutter," *PHD Thesis*, 2003.
- [51] V.P. Jilkov, D.S. Angelova, and T.A. Semerdjiev, "Design and comparison of Mode-Set Adaptive IMM Algorithms for Manoeuvring Target Tracking," *Correspondance IEEE log N°. T-AES/35/1/01512*. 1999.

- [52] S.J. Julier, and J.K. Uhlmann, "Unscented filtering and nonlinear estimation," *Proceedings of IEEE*, volume: 92, Issue: 3, pages: 401-422, March 2004.
- [53] S. J. Julier, "A new method for the nonlinear transformation of means and covariances in filters and estimators," *IEEE Trans. on Automatic Control* 45, pp. 477-482, Mars 2000.
- [54] S. J. Julier, "The scaled unscented transformation," in *Proceedings of the American Control Conference*, (Anchorage, AK), 2002.
- [55] S.J. Julier, and J.K. Uhlmann, "A General Method for Approximating Nonlinear Transformations of Probability Distributions," <http://www.robots.ox.ac.uk/~siju>, August 1994.
- [56] S.J. Julier, and J.K. Uhlmann, "A general method for approximating nonlinear transformations of probability distributions," *tech. rep., Robotics Research Group, Department of Engineering Science*, University of Oxford, 1996. Available: <http://www.robots.ox.ac.uk/siju>.
- [57] S.J. Julier, and J.k. Uhlmann, "A New Extension of the Kalman filter to Nonlinear Systems," in *Proceedings of the SPIE AeroSens International Symposium on Aerospace/Defense Sensing, Simulation and controls*, pp. 20-25, (Orlando, Florida), April, 1997.
- [58] S. J. Julier, J.K. Uhlmann, and H.F. Durrant-Whyte, "A new approach for filtering nonlinear systems," in *Proceedings of the American Control Conference*, pp.1628-1632, (Seattle, WA), 1995.
- [59] S.J. Julier, J.K. Uhlmann, and H. F. Durrant-Whyte, "A New Approach for the Nonlinear Transformation of Means and Covariances in Linear Filters," *IEEE Transactions on Automatic Control*.
- [60] R.E. Kalman, "A New Approach to Linear Filtering and Prediction Problems," *Transactions ASME, Journal of Basic Engineering* .82, 35-45.1960.
- [61] Y. Kay and S. Lee, "robust 3-D motion estimation with stereo cameras on a robot manipulator," In *Proceedings of the 1991 IEEE International Conference on a Robotics and Automation*, pages 1102-1107, Sacramento, California, April 1991.
- [62] T. Kirubarajan, Y. Bar-Shalom, K.R. Pattipati, and I.Kadar, "Ground target tracking with Variable structure IMM estimator", *IEEE Transaction on Aerospace and Electronic Systems*, Vol.36, N°1, January 2000.
- [63] A.N. Kolmogoroff, "Interpolation and Extrapolation," *Bulletin of The Academic sciences of U.S.S.R. Series in Mathematics*, 5, pp.3-14. 1941.

- [64] W. Koch, "Fixed-Interval Retrodiction Approach to Bayesian IMM-MTH for Maneuvring Multiple Targets," *IEEE transactions on Aerospace and Electronic Systems* Vol.36, N°1, January 2000.
- [65] J.J. LaViola Jr, "A comparaison of unscented and extended Kalman filtering for estimation quaternion motion," *Proceedings of the American Control Conference, volume:3, 4-6 June 2003, pages:2435-2440.* 2003.
- [66] T. Lefebvre, H. Bruyninchx and J.D. Schutter," Comment on A new method for the nonlinear transformation of means and covariances in filters and estimators," *Correspondence IEEE Transactions on Automatic Control*, Sept. 2001.
- [67] L. Ljung, " Analysis of Recursive Stochastic Algorithms", *IEEE transactions on Automatic Control*, Vol. AC-22, N°. 4, August 1977.
- [68] L. Ljung, " Asymptotic Behavior of the Extended Kalman Filter as a Parameter Estimator for Linear Systems," *IEEE transactions on Automatic Control*, Vol. AC-24, N°1, February 1979.
- [69] N. Ouadeh, M. Hamerlain **M.S. Djouadi**, "Réalisation d'une tâche de positionnement d'un bras manipulateur par asservissement visuel," *CGE'02*, 17-18 Déc 2002, Bordj el Bahri, EMP.
- [70] E. Malis,"Contribution à la modélisation et à la commande en asservissement visuel," *Thèse de Doctorat, Université Rennes I*, Novembre 1998.
- [71] P.S. Maybeck,"EENG768 Multiple Model Adaptive Estimation," *Lecture Notes. Air Force Institute of Technology, Wright-Patterson Air Force Base, OH*, 2002.
- [72] P.S. Maybeck, "Stochastic Models, Estimation and control," *Mathematics in Science and Engineering, volume 141, Academic Press*, 1979.
- [73] E. Mazor, A. Averbuch, Y. Bar-Shalom, and J. Dayan, "Interacting multiple model methods in target tracking: a survey," *IEEE Transactions on Aerospace and Electronic Systems, volume: 31, Issue: 2*, April 1995.
- [74] Y. Mezouar, "Planification de trajectoires pour l'asservissement visuel", *Thèse de Doctorat, Université de Rennes I*, Novembre 2001.
- [75] B.W. Miners, "Kalman Filtring and Prediction for Hand Tracking," *Advenced Digital Signal Processing Course Projet- University of Guelph, Canada* 2001.
- [76] K. Nickels and S. Hutchinson, "Characterizing the uncertainties in point feature motion for model-based object tracking," *In Proceedings of the IROS'97 Workshop on New Trends in Image-Based Robot Servoing, pages 53-63, Grenoble, France, September 1997.*

- [77] N. P. Papanikolopoulos, P. K. Khosla, and T. Kanade, "Visual tracking of moving target by a camera mounted on a robot: a combination of control and vision," *IEEE Trans. on Robotics and Automation*, vol. 9, n° 1, pp. 14-35. Février 1993.
- [78] N. P. Papanikolopoulos, B.J. Nelson, and P.K. Khosla, "Six Degree-of-Freedom Hand/Eye Visual Tracking with Uncertain Parameters," *IEEE Transaction on Robotics and Automation*, Vol. 11, N°5, October 1995.
- [79] N.M. Peach, "Bearing-only tracking using a set of range-parameterised extended Kalman filters," *IEEE* 1995.
- [80] J. Palmqvist, "Integrity Monitoring of Integrated Satellite / Inertial Navigation Systems Using the Likelihood Ratio," *Center of Excellence ISIS and Saab Military Aircraft research report*.
- [81] Y. Ricqebourg, "Analyse de mouvements articulée : mesure et suivi 2D ; application à la télésurveillance," *Thèse de doctorat, Université de RENNES 1*, 1997.
- [82] X. Rong Li, X. Zhi, and Y. Zhang, "Multiple-Model Estimation with Variable Structure, PartIII: Model-Group Switching Algorithm", *IEEE Transaction on Aerospace and Electronic Systems*, Vol. 35, N°1, January 1999.
- [83] X. Rong Li, and Y. Zhang, "Multiple-Model Estimation with Variable Structure, Part V: Likely-Model Set Algorithm," *IEEE Transaction on Aerospace and Electronic Systems*, Vol. 36, N°2, April 2000.
- [84] C. Schell, S.P. Linder, and J.R. Zeidler, "Tracking Highly Maneuvring Targets with Unknown Behavior," *Proceedings of the IEEE*, Vol. 92, N°3, march 2004.
- [85] A. Schrott, "Feature-based camera-guided grasping by an eye in hand robot," *In Proceedings of the 1992 IEEE International Conference on Robotics and Automation*, volume 2, pages 1832-1837, Nice, France, May 1992.
- [86] I.M. Skolnik , " Introduction to Radar Systems", (*Third Edition*). New York, NY: McGraw-Hill, 2001.
- [87] J.J. E. Slotine, and S.S. Sastry , " Tracking Control of Non-linear System using Sliding Surfaces with Application to Robot Manipulators," *Int. J. Control*, 38(2), pp. 465-492. 1983.
- [88] R.O. Swain, " Contrôle de tâches référencées vison pour la navigation d'un robot mobile en milieu structuré," *thèse de Doctorat LAAS-CNRS*, 1999.

- [89] O. Tahri, "Utilisation des moments en asservissement visuel et en calcul de pose," *Thèse de Doctorat, Université de Rennes I*, Mars 2004.
- [90] A.P.K. Timcenko, A. Yoshimi, and P. Michel man, "Hand-eye coordination for robotic tracking and grasping. Visual Servoing," *ed. Hashimoto. K, pp. 33-69, World Scientific Series in Robotics and Automated Systems, vol. 7, World Scientific Press, Singapore, 1993.*
- [91] P. Tissainayagam, D. Suter, "Visual Tracking and Motion Determination using the IMM Algorithm," *14th International Conference on Pattern recognition, volume:1*, Brishane, Australia, August 16-20, 1998.
- [92] P. Tissainayagam, and D. Suter, "Motion Model Selection for Visual Feature Tracking," *Tech. Report. MECS-1997-4*, Monash University, Australia.
- [93] J.K. Tugnait, "Tracking of Multiple Maneuvring targets in Clutter Using Multiple Sensors, IMM, and JPDA Coupled Filtering," *IEEE Transactions on A&E Systems Vol.40, N°1*, January 2004.
- [94] J. K. Uhlmann, "Simultaneous map building and localization for real time applications," *Technical report, University of Oxford*, 1994. *Transfer thesis.*
- [95] W. Wen-Rong, and C. Peen-Pau, "A nonlinear IMM algorithm for maneuvering target tracking," *IEEE Transactions on Aerospace and Electronic Systems, volume: 30, Issue: 3*, April 1994.
- [96] L.E. Weis, A. C. Sanderson, and C. P. Neuman, "Dynamic sensor -based control of robots with visual feedback," *IEEE journal of Robotics and Automation, vol. 3, n° 5, pp. 404-417, octobre 1987.*
- [97] A.S. Willsky, and L.J. Harold, "A Generalized Likelihood ratio Approach to the Detection and Estimation of Jumps in Linear Systems," *IEEE* 1976.
- [98] A.S. Willsky, "A Survey of Design Methods for Failure Detection in Dynamic Systems", *Automatica, Vol.12, pp. 601-611.* 1976.
- [99] W.J. Wilson, "Visual Servo Control of Robots using Kalman Filter Estimates of Robot Pose relative to Work-Pieces," *Université de Waterloo, Ontario.*
- [100] W.J. Wilson, C.C.W. Hulls, and G.S. Bell, "Relative end-effector control using Cartesian position based visual servoing," *IEEE Transaction on Robotics and Automation, 12(5):684-696*, October 1996.
- [101] N. Wiener, "Interpolation, Extrapolation and Smoothing of Stationary Time Series," *Wiley, New York.* 1948.

- [102] N. Wiener, "Cybernetics: Or Control and Communication in the Animal and in the Machine", *MIT Press, Cambridge, Massachusetts* 1961.
- [103] A. Zolghadri, "An Algorithm for Real-Time Failure detection in Kalman Filters", *IEEE Transactions on Automatic Control. Vol.41, N°.10*, October 1996.

Publications Internationales : Revues et Périodiques

1. **M.S. Djouadi**, A. Sebbagh, D. Berkani, " IMM-UKF and IMM-EKF Algorithms for Tracking Highly Maneuvring Target ," *Archive of Contrôle Sciences, Vol:1, issue: 1, to appear on 2005.*
2. **M.S. Djouadi**, A. Sebbagh, D. Berkani, "A Nonlinear Algorithm for Tracking Highly Maneuvring Target," *Arabian Journal of Sciences and Engineering, preliminary acceptance for publication.*

Communications Internationales :

1. **M.S. Djouadi**, A. Sebbagh, D. Berkani, "A Nonlinear Algorithm for Maneuvring Target Visual-Based Tracking," *ICISIP'05, Chennai India, 4-7 Jan 2005.*
2. **M.S. Djouadi**, A. Sebbagh, D. Berkani, "IMM based UKF and IMM based EKF: A comparison," *WSEAS'05 Prague, Tcheque Republic, 13-15 March 2005.*
3. P. Danes, **M.S. Djouadi**, D. Bellot, " A 2D point-wise point motion scheme for visual-based Robotic Tasks," *SIRS'99 Portugal 1999.*
4. **M.S. Djouadi**, A. HATTALI, and D. Berkani, "IMM based particule filter for tracking maneuvering target," *accepted in WSEAS'06 Venice, Italia, 02-04 November 2005.*

Communications Nationales :

1. N. Ouadeh, M. Hamerlain, **M.S. Djouadi**, "Réalisation d'une tâche de positionnement d'un bras manipulateur par asservissement visuel," *CGE'02, 17-18 Déc 2002, Bordj el Bahri, EMP.*
2. **M.S. Djouadi**, Y. Morcelly, H. Gessas, N. Ouadeh, "Saisie d'objets par asservissement visuel d'un bras manipulateur," *CGE'03, 15-16 Fév 2004, Bordj el Bahri, EMP.*
3. **M.S. Djouadi**, A. Sebbagh, D. Berkani, "Towards an Nonlinear Algorithm for Tracking Highly Maneuvring Target," *CGE'04, 12-13 Avr 2005, Bordj el Bahri, EMP.*

Résumé

Ce travail contribue à la résolution du problème d'estimation de mouvement, et de poursuite de cibles manoeuvrantes, en utilisant des informations issues de capteurs visuels. Pour modéliser les manoeuvres des cibles, nous avons considéré des systèmes avec des sauts Markoviens. La première approche étudiée, consiste à utiliser la mesure pour estimer les paramètres inconnus de manoeuvre, et corriger les états estimés en utilisant ces paramètres. Pour ce faire, nous avons opté pour la technique du test d'hypothèses, qui grâce au GLR, nous estimons, l'instant d'apparition du saut, son amplitude, et enfin nous procédons à la correction des estimées en tenant compte du dit saut. La seconde approche étudiée et qui a suscité un intérêt particulier de notre part, consiste à utiliser une banque parallèle d'estimateurs, chacun accordé à une condition de fonctionnement différente, et puis de combiner les sorties dans une estimation moyenne pondérée, basée sur l'exécution apparente de chaque filtre élémentaire. L'algorithme IMM, est connu pour être le plus efficace, notamment lorsque les modèles d'états et/ou de mesures (considérés linéaires) changent dans temps. Cependant, lorsque ces modèles sont non-linéaires, l'algorithme IMM doit être modifié pour garantir une bonne poursuite. La première version que nous avons mis en œuvre, et que nous avons noté IMM-EKF, est à base de l'EKF, elle donne des résultats appréciables lors de faibles non-linéarités (manoeuvres douces), par contre le filtre diverge complètement lorsque nous avons affaire à de fortes non-linéarités (fortes manoeuvres). Ce problème nous l'avons résolu en proposons une autres variante de l'IMM à base de l'UKF et que nous avons noté IMM-UKF; en effet, les résultats obtenus sont très satisfaisants malgré un caractères fortement manoeuvrant de la cible traquée.

Mots clés: - Asservissement visuel, - Poursuite de cible manoeuvrante, - Estimation, - Filtrage de Kalman, - Approche modèles multiples.

Abstract

This work contributes in solving the problem of motion estimation, and target tracking by using data coming from visual sensors. In order to model the target maneuvers, we considered systems with Markovian jumps. The first approach studied, consist on the use of measure to estimate the unknown maneuver parameters, and to correct the esteemed states by these parameters. To do this, we choose the hypothesis test technique, which thanks to the GLR, we estimate, the jump apparition time, its amplitude, and then we correct the esteemed values taken account of the jump. The second approach studied and which have particularly focused our interest, consist on the use of a bank of parallel filters, each of them accorded to a different functioning, then the out puts are combined in an average weighted estimation based on the apparent execution of each elementary filter. IMM algorithm is known to be the most effective, especially when the state and/or measurement models (assumed to be linear) changes during motion transition. However, when these models are nonlinear, the IMM algorithm must be modified in order to guarantee an accurate track. The first version which we proposed and noted IMM-EKF, is based on the EKF, it gives appreciable results when there is low nonlinearities (sweet maneuvers), however it completely diverges when there is high ones (high maneuvers). To resolve this problem, we proposed a novel IMM variant based on the UKF and which we noted IMM-UKF; effectively, the obtained results are very interesting even a high maneuverability of the tracked target.

Key words: - Visual servoing, - Maneuvering target tracking, - Estimation, - Kalman filtering, - Multiple Model approach.

