

Classification crédale multi-cibles

Multi-targets evidential classification

S. Hachour¹

F. Delmotte¹

E. Lefèvre¹

D. Mercier¹

J. Klein²

J.M. Vannobel²

¹ Laboratoire de Génie Informatique et d'Automatique de l'Artois, EA 3926 LGI2A

² Laboratoire d'Automatique et du Génie Informatique et Signal

Univ. Lille Nord de France, UArtois, F-62400, Béthune, France, prenom.nom@univ-artois.fr

Univ. Lille Nord de France, USTL, F-59655, Villeneuve d'Ascq, prenom.nom@univ-lille1.fr

Résumé :

Dans cet article, on s'intéresse au problème de poursuite et de classification simultanées de plusieurs cibles. Ce travail est à rapprocher de celui de Smets et Ristic. L'article est préliminaire et fédère des approches de plusieurs travaux. L'étape de poursuite sera assurée par des filtres de Kalman et d'IMM (Interacting Multiple Model) classiques, seule l'étape de classification est assurée par des fonctions de croyance. Les objets à classer sont invariants dans le temps, et il n'y a donc pas d'étape de détection ou de suppression de cibles. Une comparaison sur un problème de poursuite d'avions permet d'illustrer quelques différences avec l'approche Bayésienne.

Mots-clés :

Suivi de cibles, classification crédibiliste, classification Bayésienne.

Abstract:

In this paper, we study the problem of joint tracking and classification of several targets. Targets are considered to be known and sufficiently separated so that they cannot be confused. Our goal is to shed light on the contribution of credal classification over the Bayesian classification. Our job is to track the movement of targets using conventional Kalman filters and IMM, and compare the performances of credal and Bayesian classification.

Keywords:

Multi-target tracking, credal classification, Bayesian classification.

1 Introduction

Dans cet article, on s'intéresse au problème de poursuite et de classification simultanées de plusieurs cibles. Ce travail est à rapprocher de ceux de Smets et Ristic basés sur des exemples académiques de poursuite d'avions. Dans le cadre Bayésien des solutions existent [4] en utilisant un modèle des cibles ainsi que

des données cinématiques (position, vitesse, etc.). Il est important de noter que classer simultanément plusieurs objets est nettement plus complexe qu'en classer un seul. Ainsi dans la règle de Bayes, il faut combiner la vraisemblance mesurée à un instant donnée avec la probabilité *a priori*. Dans le cadre multi-objets, il n'est pas évident de savoir à quelles probabilités *a priori* il faut associer les vraisemblances mesurées à un instant donné. Il y a donc une phase fondamentale, appelée phase d'association, qui n'existe pas dans le cadre mono-objet. Le lecteur intéressé pourra se référer à [3] [1].

Dans le cadre mono-objet, les travaux de Smets et Ristic [8], basés sur les fonctions de croyance, ont nettement amélioré les résultats de la classification obtenus avec une approche Bayésienne pure.

L'objectif final est de reconstruire toute une chaîne de classification multi-objets en se basant exclusivement sur des fonctions de croyances, en intégrant toutes les étapes. Les résultats présentés dans cet article sont préliminaires et se basent sur ceux obtenus dans [8], mais en l'étendant au cadre multi-objets. L'étape de poursuite sera assurée par des filtres de Kalman et d'IMM (Interacting Multiple Model) classiques, et seule l'étape de classification sera assurée par des fonctions de croyance. Les objets à classer sont invariants dans le temps, et il n'y a donc pas de gestion de

l'apparition et de disparition des cibles. Pour la partie multi-objet cet article est à rapprocher des travaux [6] [9] concernant la classification crédibiliste de plusieurs objets, mais dans ces derniers il n'y a aucun aspect de poursuite. Faute de place, le formalisme des fonctions de croyance ne sera pas exposé. Des détails sur cette théorie peuvent être trouvés dans [7].

Dans le paragraphe 2 est présenté le modèle d'évolution des cibles utilisé dans les simulations ainsi que le problème de classification. Le paragraphe 3 donne les équations des filtres IMM, à base de filtres de Kalman, pour chaque cible suivie. La phase d'association est aussi mentionnée puisque l'article traite d'un problème multi-objets. Le paragraphe 4 traite de l'étape de classification qui utilise l'étape de poursuite. Le paragraphe 5 donne de premiers résultats de simulation.

2 Modèle d'évolution des cibles

Le modèle d'évolution sera formulé pour une seule cible et sera ensuite généralisé au cas de plusieurs cibles.

Le vecteur d'état de la cible à l'instant k est noté $x_k \in R^n$, il représente les données cinématiques de la cible (position, vitesse, etc.). Un nombre s de classes c de la cible peuvent être définies :

$$C = \{c_1, c_2, \dots, c_s\}$$

Dans le contexte de la surveillance aérienne la classe peut être : un avion de ligne, un bombardier, un avion de chasse, un missile, un ovni, etc. La différenciation entre les classes s'effectue généralement à l'aide de contraintes sur la vitesse et l'accélération de la cible.

Par souci de simplicité, on considérera que l'état de la cible évolue selon un modèle linéaire sous la forme suivante :

$$x_k = F(c_i)x_{k-1} + Bu + w_k \quad (1)$$

où, $F(c_i)$ est une matrice ($n \times n$) d'état dépendante de la classe. B est une matrice d'entrée. u est une entrée déterministe. w_k est un bruit

d'état considéré Gaussien de moyenne nulle et de matrice de covariance Q .

Toujours par souci de simplicité, on considère que la mesure à l'instant k notée $z_k \in R^m$ est linéairement dépendante de l'état de la cible selon l'équation suivante :

$$z_k = Hx_{k-1} + v_k \quad (2)$$

où, H est une matrice d'observation de dimension ($m \times n$). v_k est l'erreur de mesure considérée comme étant un bruit Gaussien de moyenne nulle et de matrice de covariance R . L'estimation optimale au sens Bayésien de la classe de la cible nécessite à chaque instant k de calculer la fonction de la densité de probabilité $p(x_k, c_i/Z_k)$ correspondant à chaque classe c_i , où $Z_k = \{z_1, z_2, \dots, z_k\}$ représente la mesure cumulée à l'instant k .

3 Estimation adaptative du mouvement des cibles

Au cours du temps une cible peut effectuer de multiples mouvements, elle peut passer d'un mouvement uniforme à un mouvement accéléré ou d'un mouvement rectiligne à un mouvement circulaire, etc. Plusieurs travaux ont été développés quant à la représentation des différents mouvements que peut effectuer une cible [3]. De nos jours, il n'existe pas de modèle exhaustif qui engendre tous les modes d'évolution possibles d'une cible, c'est pour quoi on adopte une approche d'estimation adaptative du mouvement de la cible qui est une approche multimodale à base de filtres de Kalman.

L'idée est d'utiliser autant de filtres de Kalman que de modes d'évolution possibles. Un formalisme Bayésien sera utilisé pour basculer entre les modes d'évolution possibles de la cible et sélectionner le filtre de Kalman le plus vraisemblable pour estimer le mouvement de la cible. L'algorithme en question s'appelle, Interacting Multiple Model (IMM) [2] [3].

Dans le cas de plusieurs cibles, un IMM sera utilisé pour estimer indépendamment le mouvement de chacune des cibles. Les différents

IMMs n'interagissent qu'au moment d'acquérir les observations. Le mouvement des cibles est estimé en trois étapes principales : une étape de prédiction des mesures attendues des cibles, une étape d'association des observations réelles aux prédictions, et enfin une étape de mise à jour de l'estimation du mouvement de chaque cible au niveau de chaque IMM. Cette dernière étape met aussi à jour les probabilités d'appartenance à chaque mode au sein de chaque IMM.

3.1 Prédiction de l'état et de l'observation de chaque cible

On suppose que chaque IMM est constitué de r filtres de Kalman. L'algorithme commence par une initialisation du vecteur d'état \hat{x}_i et de la matrice de covariance de l'erreur d'estimation P_i de chaque filtre de Kalman (i), avec $i = 1, \dots, r$. On définit *a priori* les probabilités initiales μ_i de chaque mode et la matrice de transition Π de dimension $(r \times r)$ qui contient les probabilités conditionnelles de basculer d'un modèle à un autre. Cette matrice sert à mixer les estimations de tous les filtres d'un même IMM. L'étape de mixage s'effectue comme suit :

- Calcul des probabilités de mixage :

$$\mu_{ij}(k-1) = \Pi_{ij}\mu_i(k-1)/C_j(k-1)$$

où μ_i est la probabilité *a priori* que la cible est dans le mode i et C_j la probabilité qu'elle soit dans le mode j après interaction, cette dernière se calcule comme suit :

$$C_j(k-1) = \sum_{i=1}^r \Pi_{ij}\mu_i(k-1) \quad (3)$$

- Mixage des vecteurs d'état et des matrices de covariance :

$$\hat{x}_j^0(k-1/k-1) = \sum_{i=1}^r \mu_{ij}(k-1)\hat{x}_i(k-1/k-1) \quad (4)$$

$$P_j^0(k-1/k-1) = \sum_{i=1}^r \mu_{ij}(k-1) [P_i(k-1/k-1) + DP_{ij}(k-1)] \quad (5)$$

où, $DP_{ij}(k-1)$ est un incrément à la matrice de covariance. Il est calculé à partir de la différence entre les estimations des deux modes

i et j :

$$DP_{ij}(k-1/k-1) = Dx_{ij}(k-1)Dx'_{ij}(k-1)$$

$$Dx_{ij}(k-1) = \hat{x}_i(k-1)\hat{x}'_j(k-1)$$

- Prédiction du vecteur d'état \hat{x}_i et de la matrice de covariance P_i :

$$\hat{x}_i(k/k-1) = F\hat{x}_i^0(k-1/k-1) + Bu_i \quad (6)$$

$$P_i(k/k-1) = FP_i^0(k-1/k-1)F' + Q_i \quad (7)$$

avec F la matrice d'état, B la matrice d'entrée, Q la matrice de covariance du bruit d'état et u_i une entrée déterministe au modèle i .

- Observation prédite par chaque filtre de Kalman :

$$\hat{z}_i(k) = H\hat{x}_i(k/k-1)$$

La matrice de covariance de l'innovation du filtre i notée S_i est définie par :

$$S_i(k) = HP_i(k+1/k)H' + R$$

où, R est la matrice de covariance du bruit de mesure et H la matrice d'observation.

- Observation globale prédite pour chaque cible : à l'aide des probabilités prédites dans (3), on calcule l'observation prédite pour la cible comme suit :

$$\hat{z}(k) = \sum_{i=1}^r C_i\hat{z}_i(k)$$

$$S(k) = \sum_{i=1}^r C_iS_i(k)$$

où, S est la matrice de covariance globale prédite pour l'innovation de chaque cible.

3.2 Association des observations aux cibles

Les observations réelles z^k , avec $k = 1, \dots, K$ sont affectées aux cibles correspondantes de manière à minimiser la distance globale qui les sépare de leurs observations prédites \hat{z}^l . La matrice d'affectation contenant les différentes distances est établie comme suit :

- Matrice d'affectation :

$$M_{lk}^2 = D_{lk}^2 + \ln[|S_l|]$$

où,

$$D_{lk}^2 = \tilde{z}^{lk'} S_l^{-1} \tilde{z}^{lk}$$

et $\tilde{z}^{lk} = \hat{z}^l - z^k$, $l = 1, \dots, L$, $k = 1, \dots, K$, où L et K sont respectivement le nombre de cibles et le nombre d'observations réelles.

- Le problème d'association posé par la matrice M sera résolu à l'aide de l'algorithme des enchères [3] de manière à minimiser la distance globale entre les observations prédites et les observations réelles.

3.3 Mise à jour de l'état de chaque cible

Chaque IMM continue l'estimation de l'état de chaque cible à base de l'observation qui lui est attribuée par la phase d'association.

- Innovation de chaque filtre de Kalman :

$$\tilde{z}_i(k) = z(k) - H\hat{x}_i(k/k-1) \quad (8)$$

la distance correspondante à cette innovation se calcule comme suit :

$$d_i^2 = \tilde{z}_i' S_i^{-1} \tilde{z}_i \quad (9)$$

La distance d_i^2 sera utilisée pour calculer la vraisemblance de chaque filtre de Kalman (mode).

- Vraisemblance de chaque mode :

$$\Lambda_i(k) = \frac{\exp[-d_i^2(k)/2]}{\sqrt{(2\pi)^m |S_i(k)|}} \quad (10)$$

où, m est la dimension de l'observation.

- Mise à jour de la probabilité de chaque mode :

$$\mu_i(k) = \Lambda_i(k) C_i(k-1) / C \quad (11)$$

où, la constante de normalisation C est donnée par

$$C = \sum_{j=1}^r \Lambda_j(k) C_j(k-1)$$

- Calcul du gain de chaque filtre de Kalman :

$$K_i(k) = P_i(k/k-1) H' [H P_i(k/k-1) H' + R]^{-1} \quad (12)$$

- Mise à jour de la matrice de covariance :

$$P_i(k/k) = [I - K_i(k) H] P_i(k/k-1) \quad (13)$$

- Mise à jour de l'état :

$$\hat{x}_i(k/k) = \hat{x}_i(k/k-1) + K_i(k) [z(k) - \hat{z}'] \quad (14)$$

- Estimation globale de l'état de la cible :

$$x(k/k) = \sum_{i=1}^r \mu_i x_i(k/k)$$

4 Classification des cibles

En général, la classification s'effectue à l'aide des données cinématiques (vitesse, accélération) estimées des cibles. En connaissant *a priori* les différents modes d'évolution possibles pour chaque classe, Smets et Ristic [8] proposent d'utiliser autant d'IMMs que de classes, où, chaque IMM comprend les modes correspondant à chacune des classes.

Ristic et *al.* [4] estiment qu'il est plus judicieux de regrouper tous les modes d'évolution possibles dans un seul IMM et de récupérer la vraisemblance de chaque classe en connaissant leurs modes respectifs.

Dans ce qui suit on décrit la méthode de classification Bayésienne adoptée par Ristic et *al.* [4] et la classification crédibiliste utilisée dans [5].

4.1 Classification Bayésienne

Soit $M_C = [m_1, m_2, \dots, m_r]$ l'ensemble des modes d'évolution possibles de chaque cible. On définit les modes appartenant à chaque classe comme suit :

$M_{c_i} = [m_1, \dots, m_{r_i}]$, où, r_i est le nombre de modes de la classe c_i , avec $i = 1, \dots, n$.

Les équations (10) et (11) permettent d'avoir respectivement, la vraisemblance et la probabilité de chaque mode. La vraisemblance de chaque classe λ_i est construite comme suit :

$$\lambda_i = \sum_{j: m_j \in M_i} \mu_j' \Lambda_j \quad i = 1, \dots, n$$

avec :

$$\mu'_j = \frac{\mu_j}{\sum_{j:m_j \in M_i} \mu_j} \quad j = 1, \dots, r_i$$

Les probabilité des classes peuvent se calculer récursivement comme suit :

$$P(c_i/Z_k) = \frac{\lambda_i}{\sum_{j=1}^n \lambda_j P(c_j/Z_{k-1})} P(c_i/Z_{k-1}) \quad (15)$$

où, $P(c_i/Z_{k-1})$ représente la probabilité *a priori* de la classe c_i . Le principe de la classification Bayésienne est illustré par la figure 1.

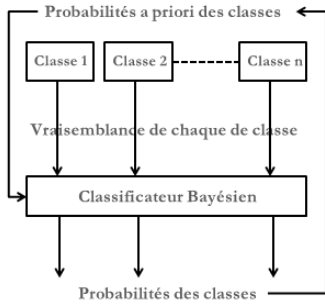


Figure 1 – Classification Bayésienne

4.2 Classification crédibiliste

En connaissant la densité de probabilité de l'innovation (8), on peut calculer la plausibilité de chaque mode [5]. Les plausibilités $Pl(\{c_i\})$ des classes peuvent être obtenues de la même manière qu'on obtient les vraisemblances des classes dans le cas Bayésien.

Une fois la plausibilité de chaque classe c_i ($c_i \in C$) obtenue à l'aide des innovations, on calcule la fonction de masse en chaque élément $A \subseteq C$:

$$m(A) = \prod_{c_i \in A} Pl(\{c_i\}) \prod_{c_i \in \bar{A}} (1 - Pl(\{c_i\}))$$

Afin de prendre une décision sur la classe de la cible suivie, on calcule la probabilité pignistique de chacune des classes à l'aide de l'équation suivante :

$$Betf(c_i) = \sum_{A:c_i \in A} \frac{1}{|A|} \frac{m(A)}{1 - m(\emptyset)}$$

où, $m(\emptyset)$ est la masse de croyance en l'ensemble vide. La figure 2 illustre les étapes de la classification crédibiliste.

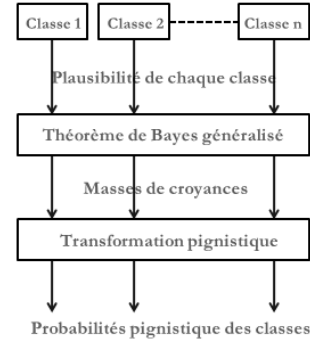


Figure 2 – Classification crédibiliste

5 Exemple de classification de deux cibles aériennes

Dans cette section on montre les résultats de la classification Bayésienne et crédibiliste de deux cibles aériennes. Les classes attendues pour les deux cibles sont les suivantes :

- Classe 1 : classe d'avions à faible capacité de manœuvre (ex : avion commercial).
- Classe 2 : classe d'avions ayant des capacités de manœuvre moyennes (ex : Bombardier).
- Classe 3 : classe d'avions agiles ayant de fortes capacités de manœuvre (ex : avion de chasse).

Le vecteur d'état $x = [x \quad \dot{x} \quad y \quad \dot{y}]$ représente la position et la vitesse sur le plan (x, y) , il est le même pour les deux cibles. Ce dernier évolue suivant le modèle donné par :

$$x_{k+1} = Fx_k + Ga_k + w_k \quad (16)$$

avec,

$$F = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad G = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix}$$

avec T , la période d'échantillonnage.

L'observation des deux cibles s'effectue selon

le modèle (2), avec :

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

Le vecteur $a = [a_x \ a_y]^T$ dans (16) représente l'accélération de la cible, elle est vue comme étant une entrée déterministe du modèle. C'est grâce à la différence dans l'accélération qu'on arrive à distinguer entre les différentes classes de la cible.

On considère que les limites en accélération sur le plan des différentes classes attendues pour la cible sont comme suit :

$$L_i \leq |a_x \pm a_y| \leq L_i$$

où, $L_i = 1g, 3g$ et $5g$ respectivement pour les trois classes c_1, c_2 et c_3 , ($g = 9.81 \text{ m/s}^2$ est l'accélération due à la gravité).

Les modes d'accélération possibles des deux cibles et leur répartition selon les différentes classes sont portés sur la figure 3.

Dans notre application, le mouvement de

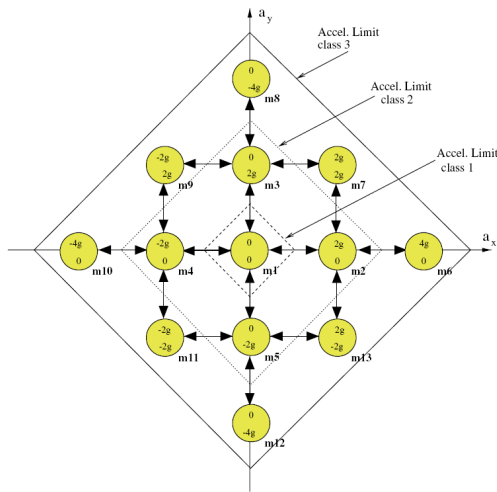


Figure 3 – Modes d'évolution [4]

chacune des cibles est estimé à l'aide d'un IMM contenant les 13 modes de la figure 3. Les modes sont répartis sur les trois classes possibles pour les deux cibles comme suit :

$M_{c_1} = [m_1]$: modes de la classe 1.

$M_{c_2} = [m_1, \dots, m_5]$: modes de la classe 2.

$M_{c_3} = [m_1, \dots, m_{13}]$: modes de la classe 3.

Les éléments non nuls de la matrice de transition Π de chaque IMM représentent les interconnexions entre les modes (voir figure 3). Ces éléments diagonaux ont la valeur $p = 0.9$, le $1 - p$ restant est uniformément réparti sur les éléments non nuls de chaque ligne, de manière à former une matrice stochastique.

5.1 Résultats de la simulation

La trajectoire des deux cibles sur le plan est montrée sur la figure 4. Les états initiaux des deux cibles sont respectivement $x_1 = [0 \ 10 \ 100 \ 10]$ et $x_2 = [0 \ 10 \ 0 \ 10]$. Comme on peut le voir sur la figure 4, la trajectoire de chacune des cibles consiste en trois segments d'évolution à vitesse constante et de deux manœuvres.

La première manœuvre s'effectue entre le

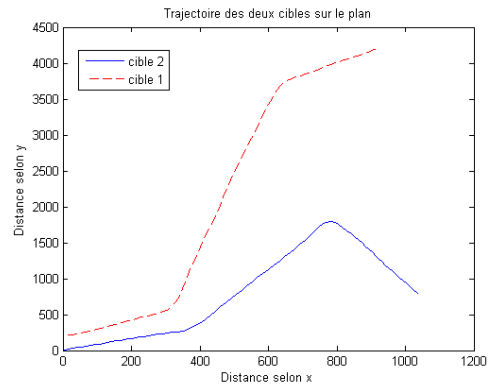


Figure 4 – Trajectoires des deux cibles

26^{ème} et 30^{ème} pas d'échantillonnage pour les deux cibles : la première cible effectue une accélération forte $a_y = 4g$ tandis que la deuxième cible effectue une accélération moyenne $a_y = 2g$ dans la même direction y .

La deuxième manœuvre s'effectue entre le 53^{ème} et 58^{ème} pas d'échantillonnage, les deux cibles effectuent une décélération forte $a_y = -4g$.

Les résultats de la classification Bayésienne des deux cibles sont respectivement portés

sur les figures 5 et 6. Ils représentent la moyenne sur 25 simulations. Comme at-

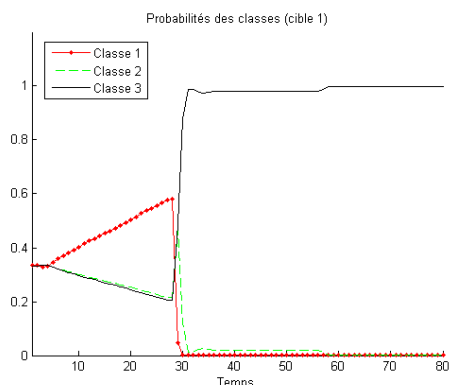


Figure 5 – Classification Bayésienne (cible 1)

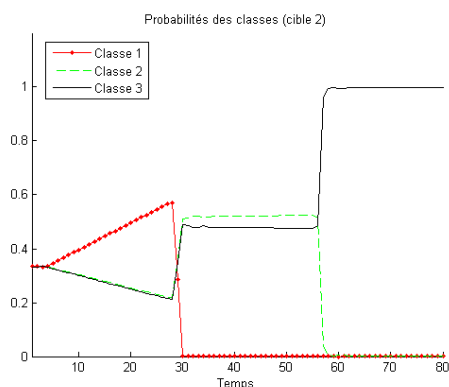


Figure 6 – Classification Bayésienne (cible 2)

tendu, on remarque que les deux cibles sont correctement classées en fin de simulation. La première cible qui était dans la classe 1 dans la première phase du mouvement passe directement à la classe 3 après sa première manœuvre forte. La deuxième cible reste en doute entre la deuxième et la troisième classe après sa première manœuvre moyenne. Elle passe à la classe 3 après sa deuxième manœuvre forte.

On remarque aussi que la classification n'est pas toute à fait adéquate. En effet, le classifieur a tendance à augmenter la probabilité de la première classe durant la première phase du mouvement alors qu'on est censé avoir un doute par-

fait entre les trois classes. Cela est dû à la différence du nombre de modes dans chaque classe, tel que plus la classe contient de modes, plus sa vraisemblance est faible.

Les figures 7 et 8 représentent respectivement les résultats de la classification crédibiliste de la première et de la deuxième cible. Les fi-

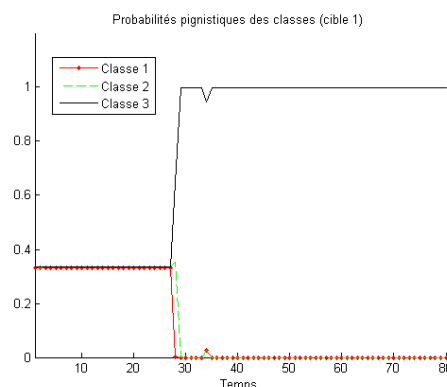


Figure 7 – Classification crédibiliste (cible 1)

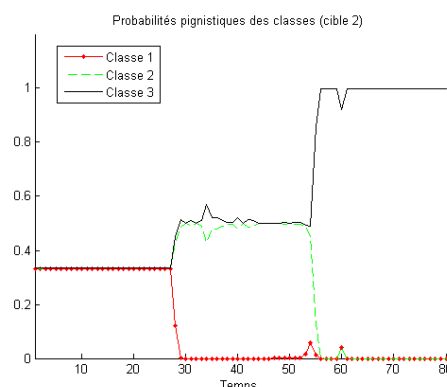


Figure 8 – Classification crédibiliste (cible 2)

gures 7 et 8 montrent que les résultats obtenus avec la classification crédibiliste sont meilleurs que ceux obtenus avec la classification Bayésienne. En effet avec l'approche crédibiliste, les deux cibles sont correctement classées durant les trois phases de leur mouvement. Le classifieur crédibiliste ne favorise pas une classe par rapport à une autre dans le cas de doute, comme c'est le cas pour la classification Bayésienne. L'aptitude du formalisme crédibiliste à associer des masses de croyance à des ensembles

dans le cas de doute, (ex : association d'une seule masse de croyance à l'ensemble des trois classes lors de la première phase du mouvement dans notre exemple), permet d'avoir des probabilités pignistiques équivalentes pour les trois classes en doute lors de la prise de décision.

6 Conclusion

La classification multi-objets est fondamentale lorsqu'il s'agit de classer simultanément plusieurs objets. Elle est nettement plus complexe que la classification mono-objet. Des solutions existent dans le cadre Bayésien. Smets et Ristic [8] ont montré que dans un cadre mono-objet les fonctions de croyance permettaient d'améliorer fortement les résultats.

Les résultats présentés dans cet article sont préliminaires. L'objectif final de ce travail est de proposer une solution complète qui imite les meilleures solutions bayésiennes dans un cadre multi-objets, mais avec des fonctions de croyance. Dans cet article, nous avons mélangé un étage de classification crédibiliste et des filtres de Kalman classiques (regroupés au sein des IMM) pour assurer la poursuite.

Nous avons adopté l'idée de Ristic et al. [4] pour le suivi du mouvement de chacune des cibles, qui consiste en l'utilisation d'un seul IMM contenant tous les modes d'évolution possibles de chacune des cibles. Nous avons comparé les résultats de la classification Bayésienne et la classification crédibiliste.

La classification crédibiliste s'avère plus intéressante.

On estime que le formalisme crédibiliste pourrait apporter une meilleure robustesse aux algorithmes de suivi et de classification d'objets, ce de par sa capacité à modéliser l'incertitude et l'imprécision à la fois.

Dans l'avenir tous les maillons de la chaîne de classification dans un cadre Bayésien pur seront généralisés avec des croyances : filtres de Kalman à base de croyances continues, phase de rejet d'hypothèses pour la détection de fausses alarmes, la confirmation et la suppression de

pistes...

Remerciements :

Ce travail est partiellement financé par le Graishym, dans le cadre du projet CROMAR (Classification Robuste d'Objets Multiples Appliquée aux Robots).

Références

- [1] A. Appriou. Multiple signal tracking processes. *Aerospace science and technology*, 1(3) :165–178, 1997.
- [2] Y. Bar-Shalom and K. Birmiwal. Variable dimension filter for maneuvering target tracking. *Aerospace and Electronic Systems, IEEE Transactions on*, (5) :621–629, 1982.
- [3] S.S. Blackman and R. Popoli. *Design and analysis of modern tracking systems*, volume 685. Artech House Norwood, MA, 1999.
- [4] B. Ristic, N. Gordon, and A. Bessell. On target classification using kinematic data. *Information Fusion*, 5(1) :15–21, 2004.
- [5] B. Ristic and P. Smets. Belief function theory on the continuous space with an application to model based classification. In *Proceedings of Information Processing and Management of Uncertainty in Knowledge-Based Systems, IPMU*, pages 4–9, 2004.
- [6] B. Ristic and P. Smets. The TBM global distance measure for the association of uncertain combat ID declarations. *Information Fusion*, 7(1) :276–284, 2006.
- [7] P. Smets and R. Kennes. The transferable belief model. *Artificial intelligence*, 66(2) :191–234, 1994.
- [8] P. Smets and B. Ristic. Kalman filter and joint tracking and classification based on belief functions in the TBM framework. *Information Fusion*, 8(1) :16–27, 2007.
- [9] N. Wartelle, F. Delmotte, and D. Gaquer. Classification de scènes à nombre d'objets inconnu. *Majestic (MANifestation des Jeunes Chercheurs STIC, novembre)*, Lorient, pages 22–24, 2006.