

# Fusion d'Informations pour la Classification Multi-capteurs, Multi-cibles

## Information Fusion for a Multi-sensor, Multi-target Classification

S. Hachour      F. Delmotte      D. Mercier      E. Lefèvre  
Laboratoire de Génie Informatique et d'Automatique de l'Artois, EA 3926, LGI2A

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

### Résumé :

La redondance d'informations est une solution habituellement proposée pour corriger l'incertitude des instruments de mesure observant un système complexe. Dans cet article, on s'intéresse au problème de suivi et de classification de plusieurs cibles à l'aide d'un ensemble de capteurs plus ou moins fiables. Chaque capteur est supposé équipé d'un calculateur lui permettant de suivre et de classer plusieurs cibles effectuant divers mouvements. Le suivi des cibles étant optimalement assuré par des IMM (Interacting Multiple Models) à base de filtres de Kalman, le résultat de la classification reste dépendant des erreurs de mesure. En vue d'avoir le meilleur résultat de classification possible, on s'est proposé de fusionner les classifications locales des capteurs, suivant différentes règles de combinaison des cadres probabiliste et crédal, et de comparer les résultats.

### Mots-clés :

Suivi multi-cibles, classification crédale, classification Bayésienne, fusion de données, association de données.

### Abstract:

Information redundancy is commonly proposed as a solution to overcome the sensors uncertainty when observing complex systems. In this article, we are interested in multiple targets tracking and classification using a set of sensors with different reliabilities. Each sensor is equipped with a processor allowing to track and classify multiple maneuvering targets. Given that the tracking task is optimally provided by Kalman filters based IMM (Interacting Multiple Models), the classification task still depends on the measurements errors. In order to have the best classification result, it is proposed to fuse the sensors local classifications following different combination rules of the Bayesian and credal frameworks, and compare the results.

### Keywords:

Multi-target tracking, credal classification, Bayesian classification, data fusion, data association.

## 1 Introduction

Cet article reprend le problème de suivi et de classification de cibles qui est abondamment étudié dans la littérature [1, 2, 7], où, à base de mesures (ex : positions en  $x$  et  $y$  du plan) prises par un ou plusieurs capteurs, on sou-

haite estimer les trajectoires d'un ensemble de cibles et les classer selon leurs propriétés dynamiques (ex : capacités de manœuvres). Plusieurs challenges sont à considérer dans ce problème, notamment, la prise en compte de la complexité des manœuvres que peuvent effectuer les cibles et les répercussions que peuvent avoir les erreurs de mesures sur la qualité du suivi et sur la classification des cibles. Le suivi du mouvement des cibles dans notre travail est assuré localement (au niveau des capteurs) par des algorithmes IMM à base de filtres de Kalman (un IMM pour une cible). Les mesures faites par les capteurs sont acheminées aux IMM par le moyen d'un algorithme d'association bidimensionnel généralisé, notamment, l'algorithme GNN (Global Nearest Neighbor) qui tend à minimiser la distance globale entre les mesures et les cibles connues. En plus de la tâche d'association, cet algorithme fournit des informations concernant les cibles nouvellement détectées ou non détectées. Ces informations sont utilisées par des fonctions score [2] pour gérer les apparitions et disparitions de cibles au niveau des capteurs.

À l'issue du processus d'estimation, et à l'aide des données cinématiques estimées, chaque capteur procède à une étape de classification locale en utilisant un formalisme Bayésien ou crédal [9]. Les classifications locales étant dépendantes des erreurs de mesure faites par les capteurs, en terme de performance, ces dernières sont fusionnées et des conclusions sont tirées quant à la robustesse de la classification globale. Les classifications locales des capteurs sont fu-

sionnées selon un ordre obtenu par un algorithme GNN généralisé, ce qui permet de gérer le fait que les capteurs n'observent pas le même nombre de cibles.

Le paragraphe 2 de cet article présente une description simplifiée du contexte de suivi multicibles, le paragraphe 3 aborde la classification locale (Bayésienne ou crédale) faite par les capteurs, ensuite la manière dont les classifications des capteurs sont fusionnées dans le paragraphe 4 et enfin, le paragraphe 5 est dédié à une application sur des cibles aériennes.

## 2 Suivi local des cibles

Les cibles dans leur environnement peuvent effectuer une multitude de manœuvres différentes (mouvements uniformes, accélérations, etc.), leur évolution peut être vue comme un processus Markovien commutant. Une modélisation possible d'un tel processus consiste à définir un nombre fini de modèles linéaires où chaque modèle représente un mode d'évolution particulier. Pour une cible  $i$  adoptant un mode d'évolution  $m_l$ , avec  $l = \{1, \dots, r\}$  et  $r$  étant le nombre de modes d'évolution possibles, l'évolution du vecteur d'état peut être décrite comme suit :

$$x^i(k) = F(m_l)x^i(k-1) + Bu^i(k) + w^i(k) \quad (1)$$

où,  $x^i(k) \in R^p$  représente le vecteur d'état de la cible  $i$  à l'instant  $k$ , avec  $i \in \{1, 2, \dots, n\}$ . La notation  $F(m_l)$  représente la matrice d'état de dimension  $(p \times p)$  qui dépend du mode d'évolution  $m_l$  et  $u^i(k)$  représente une entrée déterministe qui peut modéliser les changements d'accélération par exemple, et  $w^i(k)$  est une erreur de modélisation considérée Gaussienne à moyenne nulle ayant  $Q$  comme matrice de covariance. La matrice d'entrée est notée  $B$ . Différentes modélisations possibles du mouvement des cibles peuvent être trouvées dans [2].

Par souci de simplicité, les mesures sont considérées linéairement dépendantes du vecteur d'état et sont modélisées par :

$$z_{s_i}^j(k) = Hx^i(k) + v_{s_i}(k) \quad (2)$$

où,  $z_{s_i}^j(k) \in R^q$  représente la  $j^{\text{ème}}$  mesure reçue à l'instant  $k$ , par le capteur  $s_i$ , avec  $j \in$

$\{1, 2, \dots, m_{s_i}\}$ . La matrice d'observation de dimension  $(q \times p)$  est notée  $H$  et  $v_{s_i}(k)$  représente l'erreur de mesure faite par le capteur  $s_i$ , elle est vue comme un bruit Gaussien de moyenne nulle et de matrice de covariance  $R$ . On note que le nombre de cibles  $n_{s_i}$  connues par un capteur  $s_i$  est variant dans le temps et une mesure  $z_{s_i}^j(k)$  acquise à l'instant  $k$  peut être issue d'une cible connue (prédite), une nouvelle cible ou bien du bruit. L'ensemble des mesures prises par un capteur  $s_i$ , avec  $s_i = \{s_1, s_2, \dots, S\}$ , à un instant  $k$  est noté  $Z_{s_i}(k) = \{z_{s_i}^1(k), z_{s_i}^2(k), \dots, z_{s_i}^{m_{s_i}}(k)\}$ , avec  $m_{s_i}$  le nombre de mesures acquises par le capteur  $s_i$ . L'ensemble des mesures acquises sont utilisées par chaque capteur pour mettre à jour des cibles déjà prédites par les IMM ou créer de nouvelles cibles. Les détails concernant l'algorithme IMM peuvent être trouvés dans [1, 2]. A l'issue de la phase d'association, les IMM sont mis à jour et une estimation de l'état de toutes les cibles est faite au niveau des capteurs. On note  $\hat{X}_{s_i}(k) = \{\hat{x}_{s_i}^1(k), \hat{x}_{s_i}^2(k), \dots, \hat{x}_{s_i}^{n_{s_i}}(k)\}$ , l'ensemble des estimations faites par le capteur  $s_i$  à l'instant  $k$ .

## 3 Classification locale des cibles

Comme dans les travaux de Smets et Ristic [7, 10], la classification des cibles dans ce travail est faite à base des données cinématiques estimées des cibles. Les connaissances *a priori* sur les capacités de manœuvre des cibles nous permettent de définir un nombre  $K$  fini de classes  $C = \{c_1, c_2, \dots, c_K\}$  où, chaque classe  $c_i$  regroupe un certain nombre  $r_i$  de modes d'évolution (ex : classe contenant le mode de vitesse constante, classe contenant les modes d'accélérations moyennes, etc).

A base des vraisemblances des modes d'évolution  $m_l$  fournies par les IMM, le théorème de Bayes permet à chaque capteur  $s_i$  de classer localement les cibles  $n_{s_i}$ . Le capteur fournit un rapport  $\rho_{s_i} = \{P_{s_i}^1, P_{s_i}^2, \dots, P_{s_i}^{n_{s_i}}\}$  contenant les probabilités de classification de toutes les cibles, où par exemple,  $P_{s_i}^1 = \{P_{s_i}^1(c_1), P_{s_i}^1(c_2), \dots, P_{s_i}^1(c_K)\}$ . D'une manière analogue, et grâce au théorème de Bayes gé-

néralisé [5, 8], chaque capteur peut fournir une masse de croyance concernant la classification de chaque cible suivie. L'ensemble des fonctions de masse provenant d'un capteur  $s_i$  à l'instant  $k$  est noté  $M_{s_i} = \{m_{s_i}^1, m_{s_i}^2, \dots, m_{s_i}^{n_{s_i}}\}$ , avec  $s_i = 1, \dots, S$  et  $n_{s_i}$  le nombre de cibles. Les détails concernant les classifieurs (Bayésien et crédal), utilisés par les capteurs peuvent être trouvés dans [6, 7, 10]. On note que les masses de croyance contenues dans les rapport  $M_{s_i}$  peuvent être transformées en probabilités pignistiques en vue de prendre des décisions de classification locales, ou bien elles sont conservées pour une classification globale, où elles sont fusionnées à l'aide des lois qui sont décrites dans la section suivante. La transformation pignistique se fait comme suit :

$$\text{Bet}P(c_i) = \sum_{c_i \in A} \frac{1}{|A|} \frac{m(A)}{1 - m(\emptyset)}, \quad (3)$$

où  $A \subseteq C$  et  $m(\emptyset)$  représente la masse de croyance de l'ensemble vide.

#### 4 Classification globale

Sachant que les capteurs sont en général sujets à des erreurs de détections, et des performances de classification amoindries à cause des erreurs de mesure, cette section sera dédiée à la fusion des informations provenant des capteurs afin d'avoir une meilleure classification des cibles. Étant donné que les capteurs n'observent pas l'environnement des cibles de la même manière (ce qui signifie que le nombre de cibles connues peut être différent d'un capteur à un autre) et que les différentes cibles ne sont pas suivies dans le même ordre par les capteurs (ex : la cible 2 vue par le capteur  $s_i$  correspond à la cible 3 vue par le capteur  $s_j$ ), la fusion des classifications locales ne peut pas être effectuée directement. Une étape d'association entre les estimations faites par les différents capteurs est nécessaire (ex : ensemble d'estimations  $\hat{X}_{s_i}$  faites par le capteur  $s_i$  et ensemble d'estimations  $\hat{X}_{s_j}$  faites par le capteur  $s_j$ ). Le processus de la classification globale est effectué selon les étapes suivantes :

1. association entre les estimations des capteurs (track-to-track) : soit une matrice de distances Euclidiennes  $[D_{i,j}] \in R^{n_{s_i} \times n_{s_j}}$  entre les  $n_{s_i}$  cibles connues par le capteur  $s_i$  et les  $n_{s_j}$  cibles connues par le capteur  $s_j$ , et soit une matrice auxiliaire  $\Psi = [\psi_{i,j}]$ , tel que  $\psi_{i,j} = \{0, 1\}$ , le problème d'association entre les deux ensembles  $\hat{X}_{s_i}$  et  $\hat{X}_{s_j}$  peut être posé comme suit :

$$\text{minimiser } \sum_{i=1}^{n_{s_i}} D_{i,j} \psi_{i,j}, \quad (4)$$

avec,

$$\sum_{i=1}^{n_{s_i}} \psi_{i,j} \leq 1, \quad \sum_{j=1}^{n_{s_j}} \psi_{i,j} \leq 1, \quad (5)$$

où,  $D_{i,j}$  est la distance Euclidienne normalisée séparant les estimations  $\hat{x}_{s_i}^i$  et  $\hat{x}_{s_j}^j$  des deux capteurs  $s_i$  et  $s_j$ .

Les contraintes formulées dans (5) signifient que les cibles estimées par un capteur donné peuvent être ou ne pas être associées aux cibles estimées par les autres capteurs (les cibles ne sont pas toutes observées par tous les capteurs). La solution au problème posé par l'équation (4), est obtenue à l'aide de l'algorithme Munkres modifié [4], elle donne une information sur les cibles communément suivies par les capteurs et les cibles qui ne sont pas suivies par tous les capteurs. Comme cela est illustré par la figure 1, la cible  $t_2$  est suivie par les trois capteurs  $s_1, s_2$  et  $s_3$ , la cible  $t_3$  est suivie uniquement par le capteur  $s_1$ , etc.

2. préparation de la classification globale : la fusion des informations suit les lois suivantes : si une cible donnée est observée par un capteur  $s_i$ , ce dernier contribue à la classification globale, avec la classification locale qu'il aura réalisée concernant la cible en question. Si une cible donnée n'est pas observée par un capteur  $s_i$ , ce dernier contribue à la classification globale avec une ignorance (équiprobabilité dans le cas Bayésien et masse de croyance vide dans le cas crédal). Pour la figure 1, par exemple,




FIGURE 1 – Exemple de trois capteurs observant partiellement 4 cibles

le capteur  $s_1$  fournit les classifications locales calculées pour les cibles  $t_1, t_2$  et  $t_3$  et une ignorance pour la cible  $t_4$ .

3. classification globale : une fois que la mise en correspondance entre les estimations des capteurs est faite, on procède à une classification globale. Les stratégies de combinaisons utilisées pour fusionner les classifications locales sont présentées dans les sections suivantes.

#### 4.1 Classification globale Bayésienne

Selon la solution obtenue dans l'étape d'association (track-to-track), les probabilités contenues dans les ensembles  $\rho_{s_i}$ , avec  $s_i = 1, \dots, S$ , sont fusionnées (conjonctivement, autres combinaisons), ensuite les probabilités globales finales des classes sont obtenues à l'aide du théorème de Bayes.

**Fusion Bayésienne conjonctive.** D'une manière générale, la fusion Bayésienne conjonctive des probabilités provenant de deux capteurs indépendants  $s_1$  et  $s_2$  est définie comme suit : la probabilité  $P_{s_1 \cap s_2}$  qu'une cible donnée appartienne à la classe  $c_j$  est calculée par :

$$P_{s_1 \cap s_2}(c_j) = \frac{P_{s_1}(c_j)P_{s_2}(c_j)}{\sum_{c_i \in C} P_{s_1}(c_i)P_{s_2}(c_i)}, \quad (6)$$

Une fois que les probabilités provenant des capteurs sont fusionnées  $P_{s_1 \cap s_2}$ , elles sont combinées avec les probabilités *a priori*  $P^{k-1}$  à l'aide du théorème de Bayes pour obtenir les probabi-

lités des classes de l'instant  $k$  :

$$P^k(c_j) = \frac{P_{s_1 \cap s_2}(c_j)P^{k-1}(c_j)}{\sum_{c_i \in C} P_{s_1 \cap s_2}(c_i)P^{k-1}(c_i)}, \quad (7)$$

avec,  $i = 1, \dots, K$  et  $K$ , le nombre de classes dans l'ensemble  $C$ .

**Autres fusions Bayésiennes.** Afin d'avoir un meilleur résultat de classification globale, d'autres opérateurs de fusion Bayésienne sont utilisés [3], et les probabilités finales des classes sont obtenues à l'aide du théorème de Bayes. La probabilité  $P_{s_1, s_2}$ , donnée par deux capteurs indépendants, qu'une cible donnée appartienne à la classe  $c_j$  est calculée par :

$$P_{s_1, s_2}(c_j) = \Phi(P_{s_1}(c_j), P_{s_2}(c_j)),$$

avec  $\Phi$  un opérateur tel que le minimum, le maximum ou la moyenne. Une fois que les vraisemblances des capteurs sont fusionnées, le résultat est utilisé pour calculer les probabilités des classes comme dans l'équation (7).

#### 4.2 Classification globale crédale

Selon la solution donnée par l'étape d'association (track-to-track), les masses de croyance  $M_{s_i}$  provenant des capteurs  $s_i = 1, \dots, S$ , sont fusionnées conjonctivement ou disjonctivement.

**Fusion crédale conjonctive.** La combinaison conjonctive crédale simplifiée à la fusion des masses de croyance  $m_{s_1}$  et  $m_{s_2}$  de deux capteurs  $s_1$  et  $s_2$  est donnée par la formule suivante :

$$m_{s_1 \odot s_2}(A) = \sum_{A_1, A_2 | A_1 \cap A_2 = A} m_{s_1}(A_1)m_{s_2}(A_2), \quad (8)$$

où,  $A \subseteq C$ .

**Fusion crédale Disjonctive.** La combinaison disjonctive des masses de croyance  $m_{s_1}$  et  $m_{s_2}$  des deux capteurs  $s_1$  et  $s_2$  est donnée par la formule suivante :

$$m_{s_1 \cup s_2}(A) = \sum_{A_1, A_2 | A_1 \cup A_2 = A} m_{s_1}(A_1)m_{s_2}(A_2). \quad (9)$$

On note que toutes les probabilités contenues dans les ensembles  $\rho_{s_i}$  et les masses de

croissance contenues dans les ensembles  $M_{s_i}$ , avec  $s_i = 1, \dots, S$ , sont combinées selon les lois décrites précédemment et selon l'ordre donné par l'association (track-to-track). Afin de prendre une décision concernant la classification des cibles, les masses de croyance résultant des fusions (conjonctive ou disjonctive) sont transformées en probabilités pignistiques suivant l'équation (3).

## 5 Application à la classification de cibles aériennes

Cette section décrit un exemple de suivi et de classification de cibles aériennes (avion de ligne, bombardier, avion de chasse, etc). Les cibles apparaissent et disparaissent aléatoirement et effectuent différentes manœuvres. La classification des cibles est basée sur la complexité des manœuvres effectuées (mouvement constant, accélérations moyennes, accélérations fortes, etc). La relation entre les différents modes d'évolution et les classes est donnée comme suit :

- classe  $c_1$  : classe des cibles ayant de faibles capacités de manœuvre (ex : avion de ligne).
- classe  $c_2$  : classe des cibles ayant des capacités de manœuvre moyennes (ex : bombardier).
- classe  $c_3$  : classe des cibles ayant des capacités de manœuvre fortes (ex : avion de chasse).

Le vecteur d'état de toutes les cibles est donné par :  $x = [x \ \dot{x} \ y \ \dot{y}]$ , il représente la position et la vitesse des cibles dans le plan  $(x, y)$ . L'évolution du vecteur d'état suit le modèle donné par l'équation (1). Les différentes manœuvres sont modélisées par une entrée déterministe variable  $u = [a_x \ a_y]^T$ , qui représente les différents modes d'accélération. La différence entre les capacités d'accélération permet de distinguer les cibles et de les classer dans l'une des classes définies précédemment. Les capacités d'accélération pour les classes définies sont exprimées par :  $-L_i \leq \{a_x, a_y\} \leq L_i$ , où  $L_i = 0g, 0.2g$  et  $0.4g$  respectivement, pour les classes  $c_1, c_2$  et  $c_3$ , avec  $g = 9.81 \text{ m/s}^2$  l'accélération terrestre. Dans notre simulation, chaque cible est suivie par un IMM contenant

13 modes d'évolution représentant toutes les manœuvres qui peuvent être effectuées dans les directions  $x$  et  $y$ . Les différents modes d'évolution sont répartis dans les trois classes  $c_1, c_2$  et  $c_3$  comme suit :

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

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

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

Suivant le modèle de l'équation (1),  $F(m_1)$ , par exemple, est équivalent à la matrice d'état  $F$ , influencée par l'entrée déterministe  $u = [0 \ 0]^T$ , ce qui correspond au mode d'évolution avec une vitesse constante. Les matrices d'état et d'entrée  $F$  et  $B$  sont données respectivement par :

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

où,  $\Delta T$  représente la période d'échantillonnage.

Dans cet exemple, deux capteurs sont utilisés pour suivre et classer les trois cibles dont les trajectoires en  $(x, y)$  sont données par la figure 2. Leurs mesures sont prises selon le modèle de l'équation (2), en utilisant la matrice d'observation suivante :  $H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$ .

Les deux capteurs sont entachés de bruits de va-

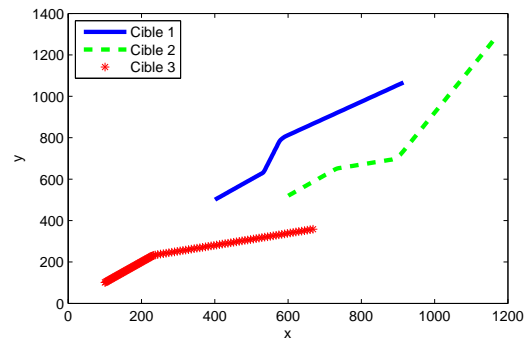


FIGURE 2 – Trajectoires des cibles

riances importantes, ce qui est censé altérer la qualité des classifications locales. Dans ce qui suit, on s'intéresse uniquement aux résultats de classification de la cible 2 (voir figure 2) qui est observée par les deux capteurs utilisés.

La cible 2 commence son évolution avec une vitesse constante, elle effectue une manœuvre

moyenne (accélération moyenne selon  $x$ ) entre le 62<sup>ème</sup> et le 65<sup>ème</sup> pas de temps, elle effectue une seconde manœuvre forte (accélération forte selon  $y$ ) entre 83<sup>ème</sup> et le 87<sup>ème</sup> pas de temps et elle termine son évolution en vitesse constante. Les résultats de classification attendus pour la cible 2 sont :

- doute entre les trois classes ( $c_1$ ,  $c_2$  et  $c_3$ ) durant la première phase du mouvement (tous les avions peuvent évoluer en vitesse constante).
- doute entre les classes ( $c_2$  et  $c_3$ ) après la première manœuvre moyenne (les avions de ligne sont supposés incapables d'effectuer des manœuvres).
- classification de la cible dans la classe  $c_3$  (avion de chasse) après sa deuxième manœuvre forte.




FIGURE 3 – Classifications Bayésienne et crédale faites par le capteur  $s_1$




FIGURE 4 – Classifications Bayésienne et crédale faites par le capteur  $s_2$

Les figures 3 et 4 montrent les résultats de classification (Bayésien et crédal) obtenus par les capteurs  $s_1$  et  $s_2$  respectivement. Deux remarques importantes peuvent être faites : on peut voir que dans les situations de doute (première phase du mouvement par exemple) là où, on est censé avoir un doute parfait entre

les trois classes, les classifieurs Bayésiens des deux capteurs ont tendance à favoriser la première classe. Cela est dû au fait que les vraisemblances des classes sont des sommes pondérées des vraisemblances des modes dans les IMM, et que la classe  $c_1$  est celle qui engendre le nombre minimum de modes et donc, sa vraisemblance est moins influencée par des modes non concernés par le mouvement actuel de la cible (ce qui est le cas pour les classes  $c_2$  et  $c_3$  qui contiennent respectivement, 5 et 13 modes d'évolution). La capacité du formalisme crédal à attribuer de la masse de croyance à des ensembles de classes lui permet de mieux gérer les situations de doute (imprécision), d'où l'amélioration importante par rapport au résultat Bayésien. Ce résultat a été démontré en premier dans [10] pour la classification d'une seule cible et étendu au cas de plusieurs cibles, dans [6]. La deuxième remarque qui peut être faite est relative à la performance des capteurs où, on peut constater une détérioration des résultats de classification, notamment, durant la première et la deuxième phases du mouvement pour les deux capteurs  $s_1$  et  $s_2$  (comportement aléatoire des probabilités/probabilités pignistiques des classes, là où on est censé avoir un doute parfait). Cette dégradation dans les résultats de classification est due à des erreurs de mesure importantes (variance : 0.6) qui font que les classifieurs favorisent les classes  $c_2$  et  $c_3$  au profit de la classe  $c_1$  par exemple (comme cela peut se voir sur les résultats des figures 3 et 4). Cela signifie qu'avec des erreurs de mesure importantes, un avion de ligne peut être pris pour un bombardier ou un avion de chasse. L'objectif de la classification globale (fusion des classifications locales) est de remonter à un résultat de classification plus fiable.

Les figures 5 les résultats de la fusion conjonctive dans les cadres Bayésien et crédal et la figure 6 montre le résultat de la fusion disjonctive crédale et le meilleur résultat Bayésien obtenu en fusionnant les vraisemblances des capteurs à l'aide de l'opérateur minimum.

La figure 5 montre que la classification globale issue de la fusion conjonctive n'améliore




FIGURE 5 – Fusions conjonctives (Bayésienne et crédale)

pas les résultats de classification obtenus au niveau des capteurs. En effet, comme la combinaison conjonctive transmet toute la croyance (probabilités/masses de croyance) sur les intersections, le résultat de la combinaison accentue la divergence causée par le bruit des capteurs. Prenons l'exemple de la classification crédale à l'instant 40 : la croyance du capteur  $s_1$  à cet instant est  $m_{s_1}(\{c_1, c_2, c_3\}) = 0.65$ ,  $m_{s_1}(\{c_2, c_3\}) = 0.35$  et la croyance du capteur  $s_2$  est  $m_{s_2}(\{c_1, c_2, c_3\}) = 0.9$ ,  $m_{s_2}(\{c_2, c_3\}) = 0.1$ , le résultat de la combinaison conjonctive est  $m_{s_1 \odot s_2}(\{c_1, c_2, c_3\}) = 0.59$ ,  $m_{s_1 \odot s_2}(\{c_2, c_3\}) = 0.41$ , ce qui explique l'accentuation de l'erreur de classification.

Le résultat de la classification Bayésienne




FIGURE 6 – Autre fusion Bayésienne et fusion disjonctive crédale

sur la figure 6 est obtenu en utilisant la vraisemblance du capteur qui s'engage le moins (opérateur  $\Phi = \text{minimum}$ ), les performances des autres opérateurs sont moins bonnes, par manque de place les résultats ne sont pas mentionnés. La remarque la plus importante est l'amélioration apportée par la fusion crédale disjonctive où le résultat obtenu s'avère beaucoup plus lisse que ceux obtenus locale-

ment par les capteurs et par la combinaison conjonctive. Cela s'explique par le fait que la combinaison disjonctive transmet toute la croyance sur l'union des classes et donc elle tend à favoriser la prudence (ignorance) et corriger les divergences occasionnées par le bruit. Pour la classification crédale à l'instant 40, le résultat de la fusion disjonctive des masses de croyances est  $m_{s_1 \oplus s_2}(\{c_1, c_2, c_3\}) = 0.96$ ,  $m_{s_1 \oplus s_2}(\{c_2, c_3\}) = 0.04$ , ce qui explique la prudence du classifieur disjonctif et la correction des divergence obtenues par les deux capteurs au même instant. Le classifieur disjonctif ne classe une cible que lorsque cette dernière effectue de vraies manœuvres et que les manœuvres sont observées par les deux capteurs comme à l'instant 87.

Les commentaires suivants concernent les résultats de la classification crédale :

- si une cible est détectée par les deux capteurs, et que les résultats de classification des capteurs sont plus ou moins détériorés, à cause des erreurs de mesure, le meilleur résultat de classification peut être obtenu, en fusionnant disjonctivement les résultats obtenus au niveau des capteurs (résultat montré dans cet article).
- si une cible n'est pas détectée par les deux capteurs, le capteur qui ne la détecte pas contribue à la classification globale par une ignorance (proposé dans la section 4). Dans ce cas le résultat de la fusion disjonctive est tout le temps erroné (suit l'avis du capteur qui ne détecte pas). Le mieux dans cette situation est de se contenter du résultat de la fusion conjonctive (résultat non montré dans cet article).

La figure 7 donne l'Erreur Quadratique Moyenne (EQM) de classification. Pour chaque valeur de variance des bruit des capteurs, l'EQM est moyennée à travers 20 simulations, avec différentes réalisations de bruits. L'EQM représente la différence entre les probabilités pignistiques attendues et celles obtenues par les capteurs 1 et 2 ainsi que celles obtenues à l'issue des classifications globales conjonctive et disjonctive. L'EQM est calculée par :




FIGURE 7 – Erreurs de classification

$EQM = (\hat{B}etp - Betp)'(\hat{B}etp - Betp)$ , où  $\hat{B}etp$  représente les un vecteur contenant les probabilités pignistiques attendues. La figure 7 montre que la classification la plus robuste est celle obtenue à l'issue de la fusion disjonctive.

## 6 Conclusion

Cet article reprend un exemple de suivi et de classification de plusieurs cibles à la fois. Nous avons opté pour une architecture multi-capteurs afin d'obtenir une meilleure classification des cibles, cela, en considérant des capteurs non fiables.

Chaque capteur, à l'aide d'un ensemble d'observations bruités, est en mesure de suivre localement une multitudes de cibles (nombre de cibles peut différent d'un capteur à un autre) ainsi que de fournir une classification locale concernant chaque objet. Les capteurs sont considérés complètement indépendants, leur classifications locales, étant détérioré par le bruit, sont fusionnées, dans le but d'obtenir une classification globale de meilleure qualité.

Pour les cibles qui sont communément observées par tous les capteurs, cet article montre que la classification globale issue d'une fusion disjonctive donne une classification meilleure que celle issue de la fusion conjonctive et celles obtenues localement par les capteurs.

## Références

[1] Y. Bar-Shalom, X.R. Li, T. Kirubarajan, and J. Wiley. *Estimation with applications*

*to tracking and navigation*. Wiley Online Library, 2001.

- [2] S.S. Blackman and R. Popoli. *Design and analysis of modern tracking systems*, volume 685. Artech House Norwood, MA, 1999.
- [3] Isabelle Bloch. Fusion d'informations numériques : panorama méthodologique. *Journées Nationales de la Recherche en Robotique*, page 79, 2005.
- [4] F. Bourgeois and J.-C Lassalle. An extension of the munkres algorithm for the assignment problem to rectangular matrices. *Communications of the ACM*, 14(12) :802–804, 1971.
- [5] F. Delmotte and P. Smets. Target identification based on the transferable belief model interpretation of Dempster-Shafer model. *IEEE Transactions on Systems, Man and Cybernetics, Part A : Systems and Humans*, 34(4) :457–471, 2004.
- [6] S. Hachour, F. Delmotte, É. Lefèvre, D. Mercier, J. Klein, and Vannobel J-M. Classification crédale multi-cibles. *21eme Rencontres Francophone sur la Logique floue et ses Applications (LFA2012)*, pages 201–208, 2012.
- [7] B. Ristic, N. Gordon, and A. Bessell. On target classification using kinematic data. *Information Fusion*, 5(1) :15–21, 2004.
- [8] P. Smets. Belief functions : the disjunctive rule of combination and the generalized bayesian theorem. *International Journal of Approximate Reasoning*, 9(1) :1–35, 1993.
- [9] P. Smets and R. Kennes. The Transferable Belief Model. *Artificial intelligence*, 66(2) :191–234, 1994.
- [10] 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.