

Poursuite de cible par un senseur mobile; Repérage multisenseur de la position du senseur mobile

Marc BLANC-PATIN, Marion CHEVALIER, Audrey DUPONT, Emmanuel MONFRINI, Yohan PETETIN

Laboratoire CITI, Telecom SudParis, Institut Mines- Telecom
9 rue Charles Fourier, 91011 Evry Cedex, France

Marc.Blanc-Patin@telecom-sudparis.eu Marion.Chevalier@telecom-sudparis.eu,
Audrey.Dupont@telecom-sudparis.eu, Emmanuel.Monfrini@telecom-sudparis.eu,
Yohan.Petetin@telecom-sudparis.eu

Résumé – Nous traitons ici de la question du pistage, en temps réel, d’une cible mobile à partir d’un senseur, lui-même, mobile. L’originalité du problème traité tient au fait que les mesures (position des balises et trajectoire de la cible) sont transmises, sous la forme de coordonnées polaires, dans le repère du senseur mobile. L’utilisation d’un unique filtre, permettant de traiter simultanément toutes les sources n’étant pas possible, nous proposons de fusionner l’information issue des senseurs indépendants, proprioceptifs et extéroceptifs, afin d’optimiser la localisation du senseur mobile dont dépend le pistage de la cible. Nous montrons que le filtrage de Kalman "unscented" (UKF) est plus adapté que le filtrage de Kalman classique (KF) pour ce type de problématique et nous mettons également en évidence l’intérêt de la fusion des différentes sources pour la localisation et l’orientation du senseur mobile.

Abstract – In this communication, we focus on the issue of tracking in real time a moving target from a sensor which is mobile too. The originality of the problem lies in the fact that the measures (targets position and targets trajectory) are expressed in the polar reference of the mobile sensor. The use of a single filter to process all the sources simultaneously was not possible so we propose to merge data from independent sensors to optimize the sensor location from which directly depends the target tracking. We show that the unscented Kalman filter (UKF) is more suitable than the classic Kalman filter (KF) for such a problem. We also highlight the interest of merging different sources for estimate the location and the orientation of the sensor.

1 Introduction

Dans le cadre de la Coupe de France de Robotique 2013 ont été organisés des matchs entre deux équipes qui s’affrontaient par l’intermédiaire de leurs robots. Une aire de jeu standard étant déterminée, les robots devaient s’y déplacer afin d’y effectuer différentes actions permettant de marquer des points, tout en évitant soigneusement leurs adversaires ainsi que les différents obstacles destinés à compliquer les déplacements.

Sur la figure 1 représentant une table de jeu standard, l’aire de jeu est délimitée par le rectangle jaune. Le robot senseur (S) est représenté par le carré bleu et le robot cible ennemi (E) est représenté par le carré rouge. Le triangle grisé indique l’orientation de S . La position réelle de chacune des trois balises fixes dans le repère de la table est connue. Les disques blancs sont des obstacles.

Les positions des balises ainsi que celles de E sont mesurées 10 fois par seconde et fournissent quatre suites d’observations vectorielles : d’une part $\{Y_k^1\}_{k \geq 0}$, $\{Y_k^2\}_{k \geq 0}$, $\{Y_k^3\}_{k \geq 0}$, $\{Y_k^E\}_{k \geq 0}$ qui sont respectivement les positions de la balise fixe 1, de la balise fixe 2, de la balise fixe 3 et du robot ennemi dans le repère de S (en mouvement). Ces mesures sont principalement perturbées par la pollution lumineuse, les erreurs de transmissions et la distance de S aux balises ou à E . On dis-

pose, d’autre part, de $\{Y_k^{od}\}_{k \geq 0}$, la position de S mesurée, dans le repère de la table, par un odomètre embarqué. L’odomètre permet également de mesurer l’orientation de S par rapport à sa position d’origine ce qui permet d’estimer l’orientation du repère mobile lié à S par rapport au repère fixe de la table de jeu. La précision des mesures de l’odomètre diminue au cours du temps, au fur et à mesure des déplacements et des changements de direction du robot. Notons dès maintenant que ce type de dispositif produit un certain nombre de valeurs aberrantes qui peuvent survenir ponctuellement ou par séries. Nous avons éliminé ce problème en bornant la différence acceptable entre deux mesures successives.

L’objectif, fixé par les contraintes de jeu, est d’affiner la connaissance des vecteurs vitesse et position du robot senseur et du robot cible afin d’optimiser les déplacements de S et mettre en oeuvre une stratégie de jeu gagnante. Nous lui fournirons les suites $X^S = [\hat{S}_x(k), \hat{S}_x(k), \hat{S}_y(k), \hat{S}_y(k)]_{k \geq 0}^T$ et $X^E = [\hat{E}_x(k), \hat{E}_x(k), \hat{E}_y(k), \hat{E}_y(k)]_{k \geq 0}^T$ donnant, la position et la vitesse estimées respectives de S et de E dans le repère cartésien de la table (O, \vec{x}, \vec{y}) .

Nous nous penchons, dans un premier temps, sur le problème d’estimation de l’état caché à partir de chacune des sources et nous montrons, dans ce cadre, que le filtrage de Kalman

"unscented" (UKF) est plus adapté que le filtrage de Kalman classique (KF). Dans un second temps, nous mettons en évidence l'intérêt de la fusion des différentes sources pour la localisation et l'orientation du capteur mobile. Ces différents résultats sont illustrés par des exemples dans le cadre de situations de jeu particulières.

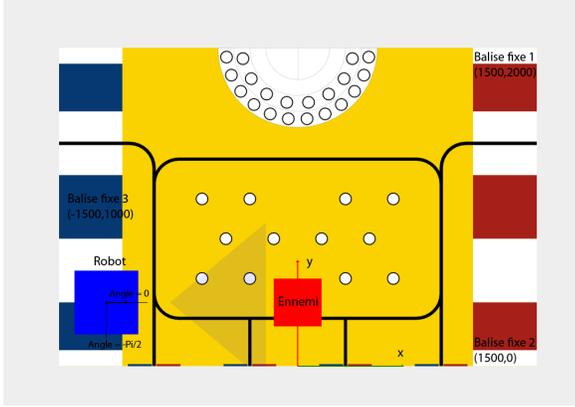


FIGURE 1 – Caractéristiques de l'aire de jeu

2 Le filtrage statistique

2.1 Modèle statistique

Dans tout ce travail, nous supposons les états cachés (positions et vitesses du capteur et de la cible) comme des variables aléatoires $X_{0:k}$ et les observations produites par chacune des sources comme des réalisations de variables aléatoires $Y_{0:k}$. La loi du couple (X, Y) liant les variables observables et les états cachés est supposé ici être celle d'une chaîne de Markov cachée, c'est à dire

$$p(x_{0:k}, y_{0:k}) = p(x_0) \prod_{i=1}^k f_{i|i-1}(x_i|x_{i-1}) \prod_{i=1}^k g_i(y_i|x_i). \quad (1)$$

Précisons cette modélisation et en particulier le choix des $f_{i|i-1}$ et des g_i .

La loi $f_{i|i-1}$ représente la dynamique du capteur ou de la cible et sera représentée par une gaussienne,

$$f_{i|i-1}(x_i|x_{i-1}) = \mathcal{N}(x_i; Fx_{i-1}; \sigma_Q^2 \times Q). \quad (2)$$

avec

$$F = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (3)$$

$$Q = \begin{bmatrix} \frac{T^3}{3} & \frac{T^2}{2} & 0 & 0 \\ \frac{T^2}{2} & T & 0 & 0 \\ 0 & 0 & \frac{T^3}{3} & \frac{T^2}{2} \\ 0 & 0 & \frac{T^2}{2} & T \end{bmatrix}. \quad (4)$$

Pour les observations, nous ne connaissons pas la loi suivie par le bruit. Nous considérons par conséquent deux possibilités. Dans le premier cas, nous convertissons les mesures polaires fournies par chaque capteur en mesures cartésiennes que l'on suppose, alors, bruitées par un bruit gaussien. Nous avons donc

$$g_i(y_i|x_i) = \mathcal{N}(y_i; \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} x_i; \underbrace{\begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix}}_{R_{car}}). \quad (5)$$

Dans le second cas, nous travaillons directement avec les mesures en coordonnées polaires, que l'on suppose bruitées par un bruit gaussien. Nous avons donc

$$g_i(y_i|x_i) = \mathcal{N}(y_i; \begin{bmatrix} \tan^{-1}(p_y/p_x) \\ \sqrt{p_x^2 + p_y^2} \end{bmatrix}; \underbrace{\begin{bmatrix} \sigma_a^2 & 0 \\ 0 & \sigma_r^2 \end{bmatrix}}_{R_{pol}}). \quad (6)$$

2.2 Le filtrage

Dans le cas du modèle d'observation (5), la loi de filtrage $p(x_k|y_{0:k})$ est une gaussienne, $p(x_k|y_{0:k}) = \mathcal{N}(x_k; m_{k|k}; P_{k|k})$ dont les paramètres sont propagés par le filtre de Kalman, composé d'une étape de prédiction,

$$m_{k|k-1} = Fm_{k-1|k-1}, \quad (7)$$

$$P_{k|k-1} = FP_{k-1|k-1}F^T + Q, \quad (8)$$

$$(9)$$

ainsi que d'une étape de mise-à-jour,

$$m_{k|k} = m_{k|k-1} + K_k(y_k - H_k m_{k|k-1}), \quad (10)$$

$$P_{k|k} = (I - K_k H)P_{k|k-1}, \quad (11)$$

$$K_k = P_{k|k-1}H^T(H P_{k|k-1}H^T + R). \quad (12)$$

Dans ce cas, $E(X_k|Y_{0:k})$ est calculable exactement, ce qui présente un avantage algorithmique évident par rapport aux méthodes nécessitant une approximation de ces espérances conditionnelles. Le KF est tout à fait adapté à l'estimation des trajectoires de S mesurées par l'odomètre dans le repère cartésien de la table, comme le montre les figures 2 et 3.

Le choix de ramener les mesures des différentes balises dans le repère cartésien de la table afin d'estimer, par le KF, la trajectoire de S mesurée par rapport aux dites balises et celle de E mesurée par rapport à S est plus discutable. En effet, les mesures cartésiennes de ces positions ne peuvent être obtenues qu'à travers une transformation non linéaire des mesures polaires originelles; le bruit de ces mesures (dont la nature est inconnue mais qui peut être supposé gaussien) se voit donc modifié par le changement de repère et le bruit résultant n'est pas en adéquation avec les hypothèses du filtrage linéaire. L'utilisation du KF peut cependant présenter un intérêt en terme de temps de calcul par rapport aux approximations non-linéaires. Notre objectif étant de travailler en temps réel nous mettons le KF en concurrence avec les filtres non linéaires.

Remarque 1 Le modèle d'observation (6), conduit naturellement à envisager le recours au filtrage particulière [2], basé sur

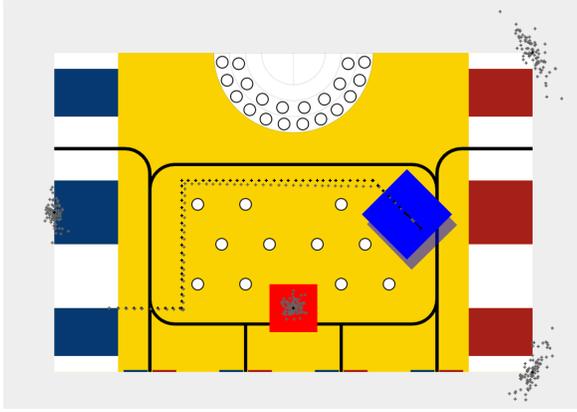


FIGURE 2 – Exemple de scénario où le robot adverse est immobile

des tirages aléatoires, et qui permet d'approcher la loi $p(x_k|y_{0:k})$. Dans le cas de notre problème, une étude préliminaire a montré que le gain en performance de ces méthodes était limité par rapport au coût de calcul important requis, qui est d'autant plus pénalisant pour l'application considérée qui exige un traitement des données en temps réel.

Dans le cas du modèle d'observation (5), l'étape de mise-à-jour n'est plus faisable exactement, à cause de la non linéarité des fonctions impliquée dans la loi de g_n . Pour pallier à ce problème, une méthode bien connue consiste à utiliser la transformation sans parfum (UT) [3]. Dans ce cas, un ensemble de « sigma »-points, centrés autour $m_{k|k-1}$ est propagé par la fonction $[\tan^{-1}(p_y/p_x), \sqrt{p_x^2 + p_y^2}]^T$ et les équations de mise-à-jour (10)-(12) sont appliquées à tous les sigma-point, qui sont finalement pondérés.

3 Fusion de données

Le modèle d'observation non linéaire (6), ne permet pas d'utiliser un unique filtre reposant sur un vecteur d'observation augmenté et qui contiendrait, à un instant donné, les observations des différents capteurs. De plus, contrairement aux mesures des balises, celles de l'odomètre sont effectuées dans le repère de la table. La prise en compte d'un maximum d'information pour atteindre notre objectif nécessite donc le développement d'une méthode de fusion permettant de produire un unique estimateur, à partir des estimateurs d'intérêts issus de chaque capteur.

Grâce aux méthodes précédentes, nous disposons d'estimations de la position de différentes balises fixes (3 dans notre exemple) dans le repère du senseur, ainsi que d'une estimation de la trajectoire et de l'orientation de notre senseur, dans le repère de la table, grâce à un odomètre. Notre but étant d'obtenir un unique estimateur du vecteur d'état X^S de S dans le repère de la table, différents modèles de fusion peuvent être proposés.

- on peut en effet supposer que la confiance prêtée à chaque estimation est identique et que les estimateurs doivent être pondérés de la même manière (fusion1).

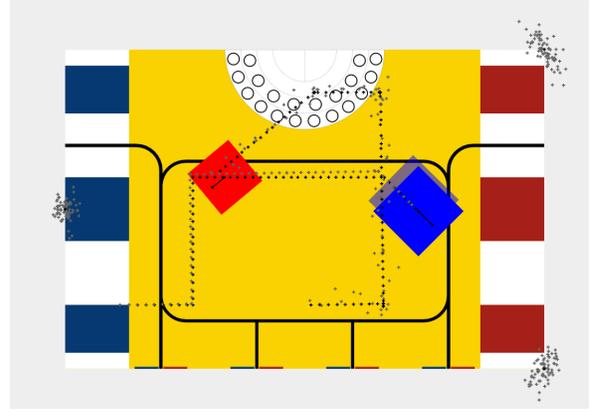


FIGURE 3 – Exemple de scénario où le robot adverse est en mouvement

- On peut également supposer que l'estimation de la position d'une balise est d'autant meilleure que la distance d_i estimée entre le senseur et la balise est faible. A l'instant k , le vecteur d'état estimé est alors donné par (fusion2)

$$\hat{x}_k = \frac{1}{1 + \sum_{i=1}^3 \frac{1}{d_i^2}} \left(\sum_{i=1}^3 \frac{1}{d_i^2} \hat{x}_k^i + \hat{x}_k^{od} \right).$$

- Enfin, on peut prendre en compte le fait que la qualité de l'estimateur lié à l'odomètre se dégrade au cours du temps. Dans ce cas, le vecteur d'état estimé est donné par (fusion3)

$$\hat{x}_k = \frac{1}{\exp(-\lambda t) + \sum_{i=1}^3 \frac{1}{d_i^2}} \left(\sum_{i=1}^3 \frac{1}{d_i^2} \hat{x}_k^i + \exp(-\lambda t) \hat{x}_k^{od} \right),$$

Les trois modes de fusion évoqués ci-dessus et basés sur des calculs barycentriques peuvent être utilisés de deux façons différentes. On peut, en effet, mener à bien de manière indépendante les filtrages des balises et de l'odomètre et construire, sans que cela ait d'impact sur les différents filtrages, les estimations de trajectoire que l'on renvoie. On peut, à l'inverse, mettre les algorithmes en symbiose en réinjectant, au moment de la mise à jour dans les différents filtres, l'unique valeur fusionnée. L'idée est de faire profiter chaque filtrage d'une mise à jour a priori plus pertinente et d'amener indirectement chaque filtre à la recherche d'une estimation unique.

4 Simulations

4.1 Sources indépendantes

Dans cette partie nous testons, sur une base de 20 scénarios du type de ceux présentés figures 2 et 3, les effets de l'utilisation du filtre de Kalman et de l'UKF sur l'estimation des trajectoires du senseur S lorsque l'on considère les sources de mesure comme indépendantes. Le tableau 1 présente les moyennes des erreurs quadratiques moyennes obtenues lors de filtrages indépendants des trajectoires des trois balises.

	Balise 1	Balise 2	Balise 3
Filtrage KF	749.04	5428.8	3010.6
Filtrage UKF	57.67	4289.8	2216.3

TABLE 1 – Comparaison des performances pour le KF et l’UKF

Ce tableau permet de confirmer que l’hypothèse de linéarité n’est pas raisonnable pour le filtrage des balise et que l’UKF est bien plus efficace. Compte tenu des résultats obtenus, nous pouvons désormais faire raisonnablement le choix de la méthode UKF pour le pistage de la cible E dans le repère du senseur S . Nous intégrerons donc la poursuite de la cible dans la partie suivante.

4.2 Sources fusionnées

L’objectif est ici de comparer, sur les deux scénarios précédents, l’intérêt des différentes règles de fusion ainsi que la pertinence ou non du choix d’un fonctionnement symbiotique des filtres.

En moyenne, sur la base des 20 scénarios déjà utilisés ci-dessus, l’erreur quadratique moyenne commise par des filtrages indépendants diminue d’un facteur 10^2 grâce aux méthodes de fusion. Bien que fusion1 permette un gain certain, ce sont surtout le méthodes fusion2 et surtout fusion3 qui sont à privilégier. On constate sur cette même base un gain moyen de l’ordre de 10% lorsque les filtres sont utilisés en symbiose.

Les figures 4 à 7 illustrent la qualité de la méthode proposée dans le cadre des scénarios des figures 2 et 3. On y trouve en noir, les trajectoires réelles, en rouge, les observations, en vert, les résultats du filtrage UKF et en bleu, ceux obtenus par KF.

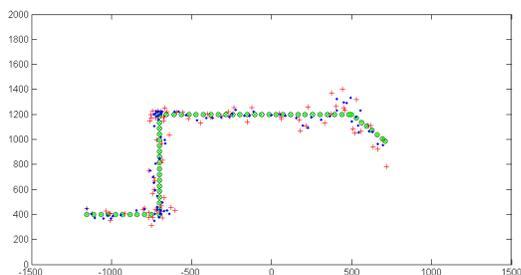


FIGURE 4 – Scénario 1 - trajectoire filtrée de S

5 Conclusion et perspectives

Les bases de la réflexion ayant été posées, il serait intéressant de se pencher sur les possibilités d’amélioration liées à l’utilisation de modèles plus complexes tels que les modèles "à sauts" [1], les modèles de Markov couple et plus généralement les modèles de Markov triplets qui pourraient permettre de créer un modèle unique permettant une fusion plus élégante des données [4].

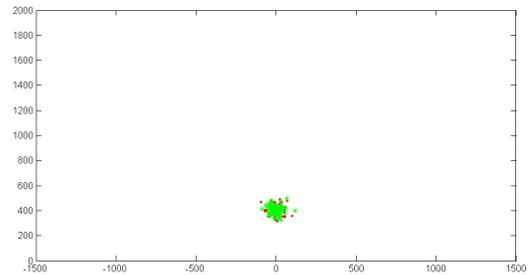


FIGURE 5 – Scénario 1 - trajectoire filtrée de E

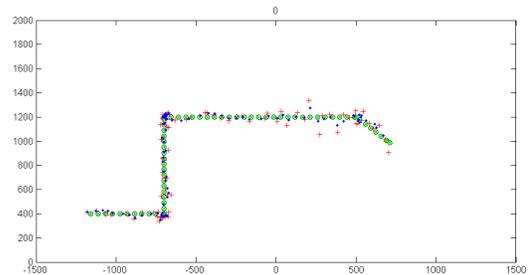


FIGURE 6 – Scénario 2 - trajectoire filtrée de S

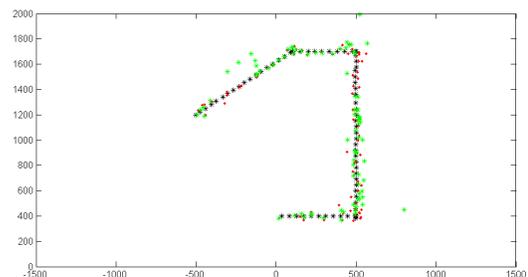


FIGURE 7 – Scénario 2 - trajectoire filtrée de E

Références

- [1] F. Caron, M. Davy, and E. Duflos. Particle filtering for multisensor data fusion with switching observation models. application to land vehicle. *55*(6), 2007.
- [2] A. Doucet, S. J. Godsill, and C. Andrieu. On sequential Monte Carlo sampling methods for Bayesian filtering. *Statistics and Computing*, 10 :197–208, 2000.
- [3] S. Julier and J. Uhlmann. Unscented Filtering and Nonlinear Estimation. In *Proceedings of the IEEE*, volume 92, pages 401–422, March 2004.
- [4] W. Pieczynski. Multisensor triplet markov chains and theory of evidence. *International Journal of Approximate Reasoning*, 2006.