

Fusion de capteurs potentiellement défaillants par filtrage particulaire

François Caron, Manuel Davy, Emmanuel Duflos, Philippe Vanheeghe
Laboratoire d'Automatique, de Génie Informatique et Signal
BP 48, Cité scientifique, 59651 Villeneuve d'Ascq Cedex, France
francois.caron@ec-lille.fr,manuel.davy@ec-lille.fr,
emmanuel.duflos@ec-lille.fr,philippe.vanheeghe@ec-lille.fr

Résumé – Cet article s'intéresse à l'estimation bayésienne d'un vecteur d'état à l'aide de données multicapteur obtenues séquentiellement, en considérant que les capteurs sont potentiellement défaillants. Un état augmenté avec les variables indicatrices de validité et les coefficients de fiabilité de chaque capteur est estimé par un algorithme de Monte Carlo séquentiel (aussi appelé filtre particulaire). Une attention particulière est portée au choix des fonctions d'importance. Un exemple est fourni montrant l'amélioration de l'estimation en présence de capteurs défaillants par rapport à un filtre particulaire classique.

Abstract – This article is interested in bayesian estimation of a state vector using sequential multisensor data, under the assumption that sensors are potentially failing. A state augmented with discrete validity variables and reliability coefficients of each sensor is estimated with a sequential Monte Carlo algorithm (also called a particle filter). Importance functions are proposed to obtain an efficient particle filter. An example is provided, showing the estimation improvement in case of failing sensors compared to a classical particle filter.

1 Introduction

Le développement de systèmes de plus en plus complexes rend nécessaire la fusion d'un grand nombre de capteurs aux données redondantes et/ou complémentaires. La complémentarité permet d'avoir accès à un plus grand nombre de variables, tandis que la redondance des informations permet d'augmenter la fiabilité des systèmes. Les capteurs ne sont cependant pas infaillibles, du fait des risques de perturbation extérieure altérant la qualité des données fournies ou de détérioration, voire de mise hors service des capteurs. Or ces défaillances doivent être détectées, afin d'éviter d'intégrer des données erronées dans le processus de fusion, causant ainsi des erreurs à long terme.

Plusieurs personnes se sont déjà penchées sur le problème de la détection de fautes, en utilisant des algorithmes de Monte Carlo séquentiels. Thrun[4] et De Freitas[2] se sont intéressés à la détection de fautes dans la robotique mobile. Ils utilisent un état hybride, dont la partie continue représente l'état du système et la partie discrète permet d'indiquer les fautes et états opérationnels des robots. Ils utilisent un algorithme de "condensation" (ou bootstrap filter) afin de faire évoluer les variables discrètes indicatrices des fautes. Le modèle d'évolution des variables discrètes est une matrice dont les coefficients sont fixés. Wu [5] définit différents modèles d'observation pour de la poursuite de contour de forme. Il emploie des variables de classe, dépendantes du clutter, afin de passer d'un modèle d'observation à l'autre. Ceci est mis en oeuvre par un filtre particulaire de type "condensation".

Toutes ces études modélisent les différentes classes de fonctionnement par des variables indicatrices discrètes,

mais sans proposer de méthode générique pour calculer une fonction d'importance suffisamment performante afin de faire évoluer ces variables indicatrices. Or, dans un algorithme de filtrage particulaire, le choix de la densité d'importance est primordial pour l'efficacité du filtre. Les apports de cet article sont les suivants

- Définition d'une fonction d'importance pour la variable indicatrice de chaque capteur, basée sur un pas de Kalman étendu
- Définition d'un coefficient de fiabilité pour chaque capteur, auquel est associé un modèle d'évolution, afin de garder en mémoire le comportement du capteur

Ceci est développé par un algorithme de Monte Carlo séquentiel, qui permet d'appréhender n'importe quel type de distribution arbitraire (non linéaire et/ou non gaussienne).

2 Modélisation de la défaillance des capteurs

L'un des buts principaux de la fusion de données multicapteur est d'estimer l'état caché \mathbf{x}_t évoluant dans un espace \mathcal{X} , de dimension $d_{\mathcal{X}}$ séquentiellement à partir de n capteurs délivrant des observations $\mathbf{z}_{k,t}$, $k = 1, \dots, n$. On suppose qu'à chaque instant t , un capteur peut être valide ou défaillant. On introduit une variable booléenne $c_{k,t} \in \{0, 1\}$ pour tout t et tout $k = 1, \dots, n$ telle que

$$\begin{aligned} c_{k,t} &= 1 \text{ si le capteur est valide à l'instant } t \\ c_{k,t} &= 0 \text{ si le capteur n'est pas valide à l'instant } t \end{aligned} \quad (1)$$

Par ailleurs, pour chaque capteur valide $k = 1, \dots, n$, on

définit le modèle d'observation suivant à l'instant t

$$\mathbf{z}_{k,t} = h_k(\mathbf{x}_t) + \mathbf{w}_{k,t} \quad (2)$$

où les bruits $\mathbf{w}_{k,t}$ sont supposés blancs, centrés et indépendants entre eux. Cette dernière équation est également notée en termes de densité de probabilité $p_k(\mathbf{z}_{k,t}|\mathbf{x}_t)$. Lorsque les capteurs ne sont pas valides, la valeur de $\mathbf{z}_{k,t}$ n'est plus reliée à l'état sous-jacent \mathbf{x}_t , et l'on suppose que $\mathbf{z}_{k,t}$ est distribué selon une densité vague $\pi_k(\mathbf{z}_{k,t})$, par exemple uniforme sur un intervalle large.

La vraisemblance tenant compte de tous les capteurs et de leur validité est donnée par

$$p(\mathbf{z}_t|\mathbf{x}_t, \mathbf{c}_t) = \prod_{k=1}^n [c_{k,t}p_k(\mathbf{z}_{k,t}|\mathbf{x}_t) + (1 - c_{k,t})\pi_k(\mathbf{z}_{k,t})] \quad (3)$$

où le vecteur des observations est $\mathbf{z}_t = [\mathbf{z}_{1,t}^T \dots \mathbf{z}_{n,t}^T]^T$ et celui des variables indicatrices est $\mathbf{c}_t = [c_{1,t} \dots c_{n,t}]^T$.

3 Modèle dynamique

Les paramètres inconnus du modèle précédent sont essentiellement l'état \mathbf{x}_t et les variables indicatrices de validité c_t . Nous proposons d'en effectuer l'estimation bayésienne, sur la base des modèles d'évolution suivants :

- Modèle de transition de l'état

$$\mathbf{x}_t = f(\mathbf{x}_{t-1}) + \mathbf{v}_{t-1} \quad (4)$$

où $f : \mathcal{X} \rightarrow \mathcal{X}$ et \mathbf{v}_{t-1} est un bruit blanc centré. La densité *a priori* de l'état ainsi défini est notée $p(\mathbf{x}_t|\mathbf{x}_{t-1})$ dans la suite. A l'instant initial, on suppose que \mathbf{x}_0 est distribué par $p_0(\mathbf{x}_0)$.

- Densité *a priori* des variables indicatrices $c_{k,t}$, $k = 1, \dots, n$

$$\begin{aligned} \Pr(c_{k,t} = 1) &= \alpha_{k,t} \\ \Pr(c_{k,t} = 0) &= 1 - \alpha_{k,t} \end{aligned}$$

soit

$$\Pr(c_{k,t}) = c_{k,t}\alpha_{k,t} + (1 - c_{k,t})(1 - \alpha_{k,t}) \quad (5)$$

où $0 \leq \alpha_{k,t} \leq 1$. Le choix des probabilités $\alpha_{k,t}$ est extrêmement sensible du point de vue de la détection de capteurs invalides. Aussi, ces probabilités seront elles-mêmes estimées. Dans la suite, on note la distribution définie par l'équation précédente par $p(c_{k,t}|\alpha_{k,t})$ pour $k = 1, \dots, n$, ou encore $p(\mathbf{c}_t|\alpha_t)$ pour l'ensemble des capteurs (avec $\alpha_t = [\alpha_{1,t} \dots \alpha_{n,t}]^T$).

- La densité *a priori* pour $\alpha_{k,t}$ est posée sous la forme d'un modèle dynamique

$$\phi(\alpha_{k,t}) = \phi(\alpha_{k,t-1}) + \epsilon_{k,t-1} \quad (6)$$

où $\epsilon_{k,t-1}$ est un bruit blanc centré gaussien, de variance $\sigma_{k,t}^\epsilon$, et ϕ est une fonction inversible telle que $\phi^{-1} : \mathbb{R} \rightarrow [0, 1]$ (dans le but d'assurer que $\alpha_{k,t}$ ne quitte pas le domaine $[0, 1]$). On peut choisir une fonction sigmoïde $\phi(\alpha) = \log \left[\frac{\alpha}{1-\alpha} \right]$. L'objectif de cette modélisation est d'inclure un effet de mémoire qui renforce la confiance dans un capteur longtemps valide ($\alpha_{k,t}$ augmente avec t), et qui entretient le doute

à propos d'un capteur souvent défaillant ($\alpha_{k,t}$ est proche de 0). Au temps $t = 1$, on suppose $\alpha_{k,0} \sim p_0(\alpha_{k,0})$. La variance $\sigma_{k,t}^\epsilon$ du bruit $\epsilon_{k,t-1}$ conditionne la dynamique d'évolution de $\alpha_{k,t}$ au cours du temps. Afin de ne pas avoir une évolution fixée à l'avance, cette variance est également estimée.

- La densité *a priori* pour $\sigma_{k,t}^\epsilon$ ($k = 1, \dots, n$) est posée sous la forme du modèle dynamique suivant

$$\log(\sigma_{k,t}^\epsilon) = \log(\sigma_{k,t-1}^\epsilon) + \lambda_k^\epsilon \quad (7)$$

où λ_k^ϵ ($k = 1, \dots, n$) sont des bruits gaussiens indépendants et centrés dont les variances σ_k^λ sont fixées.

Le modèle dynamique général est résumé par le schéma de la figure 1.

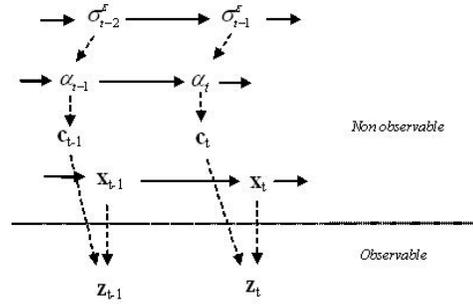


FIG. 1 – Modèle graphique dynamique

4 Algorithme de filtrage particulière

Le modèle défini à la section précédente permet, en théorie, d'effectuer l'estimation de l'état et des paramètres de validité des capteurs. En pratique, il n'est pas possible de calculer explicitement à chaque instant leur densité *a posteriori* $p(\mathbf{x}_{0:t}, \mathbf{c}_{0:t}|\mathbf{z}_{1:t})$ (où, pour un vecteur \mathbf{a}_t défini à tout instant t , la notation $\mathbf{a}_{t_1:t_2}$ fait référence à la suite $\{\mathbf{a}_{t_1}, \mathbf{a}_{t_1+1}, \dots, \mathbf{a}_{t_2}\}$).

Dans le cadre de cet article, nous nous intéressons à la distribution de filtrage $p(\mathbf{x}_t, \mathbf{c}_t|\mathbf{z}_{1:t})$ qui est la marginale à l'instant t de la distribution *a posteriori* complète $p(\mathbf{x}_{0:t}, \mathbf{c}_{0:t}|\mathbf{z}_{1:t})$. Comme son calcul analytique n'est pas envisageable, un algorithme de Monte Carlo séquentiel[3] (aussi appelé filtre particulière) est mis en oeuvre.

Algorithme de Monte Carlo séquentiel pour la fusion de capteurs potentiellement défaillants

% Etape 0 : initialisation

- Pour $i = 1, \dots, N$, générer $\mathbf{x}_0^{(i)} \sim p_0(\mathbf{x}_0)$
- Pour $i = 1, \dots, N$ et $k = 1, \dots, n$, générer $\log(\sigma_{k,0}^\epsilon) \sim p_0(\log(\sigma_{k,0}^\epsilon))$
- Pour $i = 1, \dots, N$ et $k = 1, \dots, n$, générer $\phi(\alpha_{k,0}^{(i)}) \sim p_0(\phi(\alpha_{k,0})|\sigma_{k,0}^\epsilon)$
- Faire $w_0^{(i)} \leftarrow \frac{1}{N}$

% Etape 2 : itérations

- Pour $t=1,2,\dots$ faire
 - Pour $i = 1, \dots, N$ faire
 - % Prolongation des trajectoires
 - Générer $\tilde{\mathbf{c}}_t^{(i)}$ selon $q(\mathbf{c}_t|\mathbf{x}_{t-1}^{(i)}, \mathbf{z}_t)$
 - Générer $\tilde{\mathbf{x}}_t^{(i)}$ selon $q(\mathbf{x}_t|\mathbf{x}_{t-1}^{(i)}, \tilde{\mathbf{c}}_t^{(i)}, \mathbf{z}_t)$
 - Générer $\phi(\tilde{\alpha}_{k,t}^{(i)})$ selon $q(\phi(\alpha_{k,t})|\alpha_{k,t-1}^{(i)}, \tilde{\mathbf{c}}_{k,t}^{(i)}, \sigma_{k,t-1}^{\epsilon(i)})$ pour $k = 1..n$
 - Générer $\log(\tilde{\sigma}_{k,t}^{\epsilon(i)})$ selon $q(\log(\sigma_{k,t}^{\epsilon(i)})|\sigma_{k,t-1}^{\epsilon(i)}, \tilde{\alpha}_{k,t}^{(i)}, \alpha_{k,t-1}^{(i)})$ pour $k = 1..n$
 - Pour $i = 1, \dots, N$ mettre à jour les poids récursifs selon

$$\tilde{w}_t^{(i)} \propto w_{t-1}^{(i)} \frac{p(\mathbf{z}_t|\tilde{\mathbf{x}}_t^{(i)}, \tilde{\mathbf{c}}_t^{(i)})p(\tilde{\mathbf{x}}_t^{(i)}|\mathbf{x}_{t-1}^{(i)})p(\tilde{\mathbf{c}}_t^{(i)}|\tilde{\alpha}_{k,t}^{(i)})}{q(\tilde{\mathbf{x}}_t^{(i)}|\mathbf{x}_{t-1}^{(i)}, \tilde{\mathbf{c}}_t^{(i)}, \mathbf{z}_t)q(\tilde{\mathbf{c}}_t^{(i)}|\mathbf{c}_{t-1}^{(i)}, \mathbf{z}_t)} \times \frac{\prod_{k=1}^n [p(\phi(\tilde{\alpha}_{k,t}^{(i)})|\alpha_{k,t-1}^{(i)}, \sigma_{k,t-1}^{\epsilon(i)})p(\log(\tilde{\sigma}_{k,t}^{\epsilon(i)})|\sigma_{k,t-1}^{\epsilon(i)})]}{\prod_{k=1}^n [q(\phi(\tilde{\alpha}_{k,t}^{(i)})|\alpha_{k,t-1}^{(i)}, \tilde{\mathbf{c}}_{k,t}^{(i)}, \sigma_{k,t-1}^{\epsilon(i)})q(\log(\tilde{\sigma}_{k,t}^{\epsilon(i)})|\sigma_{k,t-1}^{\epsilon(i)}, \tilde{\alpha}_{k,t}^{(i)}, \alpha_{k,t-1}^{(i)})]}$$

avec $\sum_{i=1}^N \tilde{w}_t^{(i)} = 1$,

- % Rééchantillonnage

Dans l'algorithme précédent, la trajectoire de chaque particule $i = 1, \dots, n$ est prolongée à l'aide des lois

$$q(\mathbf{c}_t|\mathbf{c}_{t-1}^{(i)}, \mathbf{z}_t), q(\mathbf{x}_t|\mathbf{x}_{t-1}^{(i)}, \tilde{\mathbf{c}}_t^{(i)}, \mathbf{z}_t),$$

$$q(\phi(\alpha_{k,t})|\alpha_{k,t-1}^{(i)}, \tilde{\mathbf{c}}_{k,t}^{(i)}, \sigma_{k,t-1}^{\epsilon(i)}) \text{ et}$$

$q(\log(\sigma_{k,t}^{\epsilon(i)})|\sigma_{k,t-1}^{\epsilon(i)}, \tilde{\alpha}_{k,t}^{(i)}, \alpha_{k,t-1}^{(i)})$, dont le choix est laissé à l'utilisateur, sous réserve de validité de l'échantillonnage préférentiel (importance sampling). En particulier, il est important de sélectionner $q(\mathbf{c}_t|\mathbf{x}_{t-1}^{(i)}, \mathbf{z}_t)$ avec soin : en effet, le nombre de valeurs possible du vecteur \mathbf{c}_t est 2^n , et tester toutes les combinaisons est hors de portée. Il est donc nécessaire que la loi $q(\mathbf{c}_t|\mathbf{x}_{t-1}^{(i)}, \mathbf{z}_t)$ propose les configurations les plus probables. La loi proposée dans la section suivante utilise un test statistique sur la différence entre l'observation et la prédiction de l'observation délivrée par un pas de Kalman étendu afin de définir la validité d'un capteur.

5 Lois d'évolution de $\mathbf{c}_t|\mathbf{z}_t, \mathbf{x}_{t-1}^{(i)}$ et $\mathbf{x}_t|\mathbf{x}_{t-1}^{(i)}, \tilde{\mathbf{c}}_t^{(i)}, \mathbf{z}_t$

On utilise un filtre de Kalman étendu multicapteur afin de faire évoluer chaque particule, en prenant comme moyenne et matrice de covariance à l'instant précédent les valeurs $\hat{\mathbf{x}}_{t-1|t-1}^{(i)} = \mathbf{x}_{t-1}^{(i)}$ et $P_{t-1|t-1}^{(i)} = 0$.

5.1 Phase de prédiction

La prédiction de l'état est donnée pour chaque particule par

$$\hat{\mathbf{x}}_{t|t-1}^{(i)} = \nabla f_t^{(i)} x_{t-1}^{(i)}$$

avec $\nabla f_t^{(i)} = \frac{\partial f}{\partial \mathbf{x}_t} \Big|_{\mathbf{x}_t = \mathbf{x}_{t-1}^{(i)}}$

La matrice de covariance de l'erreur de prédiction est donnée par

$$P_{t|t-1} = Q_t$$

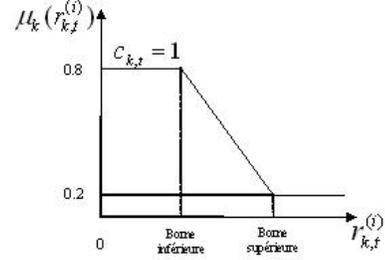


FIG. 2 – Fonction d'appartenance basée sur une règle de logique floue, qui est fonction de la valeur de l'innovation quadratique normalisée

5.2 Phase d'estimation

5.2.1 Loi de $\mathbf{c}_t|\mathbf{z}_t, \mathbf{x}_{t-1}^{(i)}$

L'innovation est définie par

$$\nu_{k,t}^{(i)} = \mathbf{z}_{k,t} - h_k(\hat{\mathbf{x}}_{t|t-1}^{(i)})$$

La matrice de covariance de l'innovation est donnée par

$$S_{k,t}^{(i)} = \nabla h_{k,t}^{(i)} P_{t|t-1} \nabla h_{k,t}^{(i)} + R_k$$

avec $\nabla h_{k,t}^{(i)} = \frac{\partial h_k}{\partial \mathbf{x}_t} \Big|_{\mathbf{x}_t = \hat{\mathbf{x}}_{t|t-1}^{(i)}}$

On pose

$$r_{k,t}^{(i)} = \left(\nu_{k,t}^{(i)} \right)^T \left(S_{k,t}^{(i)} \right)^{-1} \nu_{k,t}^{(i)}$$

l'innovation quadratique normalisée[1]. En se basant sur les tables de χ^2 , on peut définir une fonction d'appartenance $\mu_k(r_{k,t}^{(i)})$ définie pour chaque capteur selon le schéma 2.

La loi d'évolution de \mathbf{c}_t est alors définie par

$$q(\mathbf{c}_t|\mathbf{z}_t, \mathbf{x}_{t-1}^{(i)}) = \prod_{k=1}^n \left[c_{k,t} \mu_k(r_{k,t}^{(i)}) + (1 - c_{k,t})(1 - \mu_k(r_{k,t}^{(i)})) \right] \quad (8)$$

5.2.2 Loi de $\mathbf{x}_t|\mathbf{x}_{t-1}^{(i)}, \tilde{\mathbf{c}}_t^{(i)}, \mathbf{z}_t$

L'estimée est définie par

$$\hat{\mathbf{x}}_{t|t}^{(i)} = \hat{\mathbf{x}}_{t|t-1}^{(i)} + \sum_{k=1}^n \tilde{\mathbf{c}}_{k,t}^{(i)} K_{k,t}^{(i)} \nu_{k,t}^{(i)}$$

avec

$$K_{k,t}^{(i)} = P_{t|t} \left(\nabla h_{k,t}^{(i)} \right)^T R_k^{-1}$$

L'incertitude sur l'estimée est donnée par la matrice $P_{t|t}$ définie par

$$P_{t|t}^{(i)} = \left[P_{t|t-1}^{-1} + \sum_{k=1}^n \tilde{\mathbf{c}}_{k,t}^{(i)} \left(\nabla h_{k,t}^{(i)} \right)^T R_k^{-1} \nabla h_{k,t}^{(i)} \right]^{-1}$$

Les échantillons $\mathbf{x}_{0:t-1}$ sont prolongés selon la loi

$$q(\mathbf{x}_t|\mathbf{x}_{t-1}^{(i)}, \tilde{\mathbf{c}}_t^{(i)}, \mathbf{z}_t) = \mathcal{N}(\mathbf{x}_t : \hat{\mathbf{x}}_{t|t}^{(i)}, P_{t|t}^{(i)}) \quad (9)$$

6 Exemple

On considère le modèle d'évolution fortement non linéaire suivant

$$x_{t+1} = \frac{1}{2}x_t + 25\frac{x_t}{1+x_t^2} + 8\cos(1,2(t+1)) + v_t \quad (10)$$

avec $v_t \sim \mathcal{N}(v_t : 0, 10)$ et $x_0 \sim \mathcal{N}(v_t : 0, 10)$. Deux capteurs observent la valeur de x_t selon les deux modèles de mesure suivants

$$\begin{cases} z_{1,t} = \frac{x_t^2}{20} + w_{1,t} & w_{1,t} \sim \mathcal{N}(w_{1,t} : 0, 1) \\ z_{2,t} = x_t + w_{2,t} & w_{2,t} \sim \mathcal{N}(w_{2,t} : 0, 10) \end{cases} \quad (11)$$

Le premier capteur, dont la mesure est faiblement bruitée, est supposé peu fiable. Le second capteur, dont la mesure est plus bruitée, est supposé relativement fiable. A l'instant $t = 0$, les coefficients de fiabilité sont initialisés par les lois uniformes $\alpha_{1,0}^{(i)} \sim \mathcal{U}(0.4, 0.6)$ et $\alpha_{2,0}^{(i)} \sim \mathcal{U}(0.4, 0.6)$ les deux capteurs étant estimés *a priori* à 50% fiables.

L'algorithme proposé est lancé avec 200 particules pour $t = 1..150$. Dans les intervalles $T_1 = [30, 40]$ et $T_2 = [60, 100]$, on simule une défaillance du capteur 1 en rajoutant un biais aléatoire sur la mesure $z_{1,t}$.

Les résultats de l'algorithme proposé sont comparés à un algorithme de filtrage particulaire sans prise en compte des défaillances (mais avec la même distribution d'importance pour \mathbf{x}_t) et un algorithme de Kalman étendu. Les valeur de la variable indicatrice (moyennée sur l'ensemble des particules et notée c_e) et du coefficient de fiabilité (noté α_e) sont données pour chaque capteur sur les figures 3 et 4. La défaillance du capteur 1 est bien détectée (c_e est proche de 0) dans les intervalles T_1 et T_2 , et le coefficient de fiabilité baisse dans ces intervalles, pour remonter en dehors. Comme indiqué sur la figure 5, l'algorithme proposé donne de bien meilleurs résultats que le filtre particulaire standard et l'EKF en cas de défaillances de capteurs.

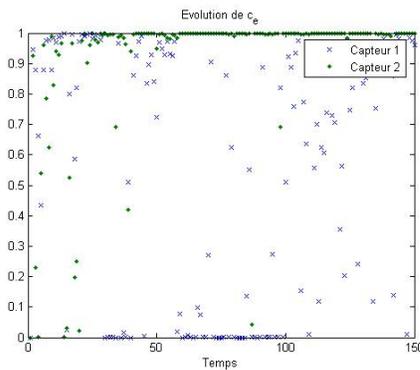


FIG. 3 – Evolution de la moyenne pondérée des variables indicatrices en fonction du temps. Le capteur 1 est détecté défaillant dans les intervalles T_1 et T_2 .

Remerciements

Ce travail est supporté par la région Nord-Pas de Calais et le Centre National de la Recherche Scientifique. Les auteurs remercient Corentin Dubois pour son aide dans la réalisation de cet article.

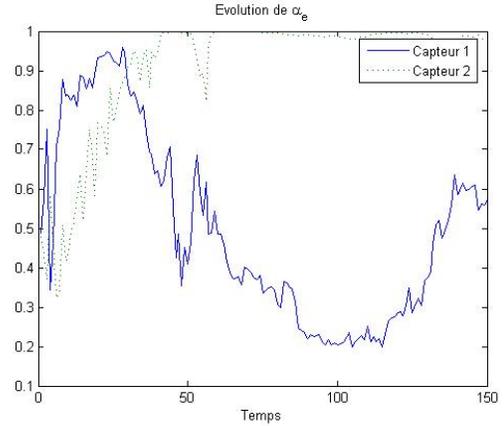


FIG. 4 – Evolution de la moyenne pondérée des coefficients de fiabilité en fonction du temps. La fiabilité du capteur 1 diminue pendant les intervalles où il est détecté comme défaillant.

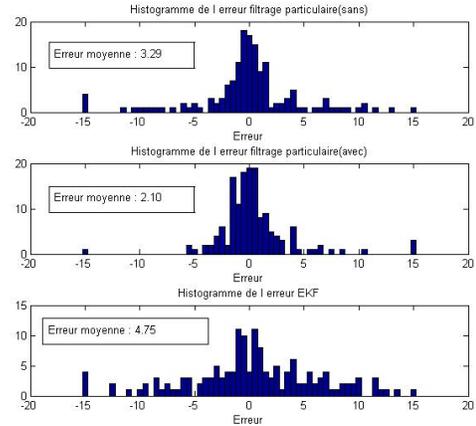


FIG. 5 – Comparaison de la distribution de l'erreur entre le filtre particulaire, l'algorithme proposé, et le filtre de Kalman étendu.

Références

- [1] Y. Bar-Shalom, X. Rong Li, and T. Kirubajan. *Estimation with applications to tracking and navigation*. Editions Wiley-Interscience, 2001.
- [2] Nando de Freitas. Rao-blackwellised particle filtering for fault diagnosis. In *Proc. Aerospace Conference*, 2002.
- [3] Arnaud Doucet, Nando de Freitas, and Neil Gordon. *Sequential Monte Carlo Methods in practice*. Springer, 2001.
- [4] Vandi Verma, Geoff Gordon, Reid Simmons, and Sebastian Thrun. Particle filters for rover fault diagnosis. *IEEE Robotics & Automation Magazine special issue on Human Centered Robotics and Dependability*, 2004.
- [5] Ying Wu, Gang Hua, and Ting Yu. Switching observation models for contour tracking in clutter. In *Proc. Aerospace Conference*, 2002.