

UTILISATION D'UNE BANQUE DE MODÈLES VARIABLE POUR LA DÉTECTION DE CHANGEMENT DE RÉGIME

Abdelfettah HOCINE, Didier MAQUIN, José RAGOT

Centre de Recherche en Automatique de Nancy - CNRS UMR 7039

Institut National Polytechnique de Lorraine

2, Avenue de la Forêt de Haye - 54 516 Vandoeuvre les Nancy

{ahocine, dmaquin, jragot}@ensem.inpl-nancy.fr

Abstract

In this paper, we are going to develop a fault detection algorithm for dynamic systems based on the IMM method (Interacting-Multiple-Model). This later is based on the interaction between several Kalman's filters in order to finding the operating mode of the system. It also needs a priori information about the switching between the various operating mode of the system modelled by a Markov's chain.

The proposed algorithm belongs to the class of supervised algorithms in the sense that the faults to be detected are a priori listed and modelled. At first, IMM method is used for fault detection in the case of a linear system characterised by a model of normal functioning and several models of faults. Then, one proposes the "sliding method" in the case of a system represented by several models where every model is associated to a particular regime of functioning and where one has to determine simultaneously active model and fault.

Key-words: fault detection, regime change detection, state estimation, multiple model, IMM.

Résumé

Dans cet article, nous développons un algorithme de détection de défauts affectant un système dynamique. Cet algorithme est basé sur l'approche IMM (Interacting-Multiple-Model) qui utilise l'interaction entre plusieurs filtres de Kalman dans le but de retrouver le mode de fonctionnement du système ; il s'appuie également sur la connaissance d'informations a priori sur les basculements entre les différents modes de fonctionnement, représentés par une chaîne de Markov.

L'algorithme proposé appartient à la classe des algorithmes supervisés dans le sens où les défauts à détecter sont a priori répertoriés et modélisés. Dans un premier temps, l'approche IMM est utilisée pour la détection de défauts dans le cas d'un système linéaire caractérisé par un modèle de bon fonctionnement et plusieurs modèles de défaut.

Ensuite, on propose la « méthode de glissement » dans le cas d'un système représenté par plusieurs modèles (système non linéaire, système à commutation ...) où chaque modèle est associé à un

régime de fonctionnement particulier et où on doit déterminer le modèle actif en même temps que le défaut.

Mots clés : détection de défaut, changement de régime, estimation d'état, multimodèle, IMM.

1. Introduction

C'est une évidence de constater que la commande des systèmes devient de plus en plus complexe ; cela est dû à la nature des systèmes mais aussi à la volonté de contrôler tous les paramètres et toutes les perturbations affectant le système. Dans cette dynamique s'est développée la discipline de la sûreté de fonctionnement et une de ses composantes connue sous le nom FDI (Fault Detection and Isolation).

Les techniques de FDI sont généralement basées sur l'estimation de l'état de fonctionnement du système et l'analyse de cet état vis-à-vis d'états de référence. En pratique, il est souvent plus simple de générer une estimation de la sortie du système. A partir de cette estimation, on calcule un résidu, différence entre la sortie mesurée et la sortie estimée, et qui a la propriété d'être sensible aux défauts. L'estimation d'état ou de sortie du système est à la base des méthodes de FDI et l'approche IMM est un outil adapté pour la détection de défauts qui elle aussi se base sur le calcul de résidus. Dans la réalité, un système peut être souvent représenté par un ou plusieurs modèles de bon fonctionnement mais également par un ensemble de modèles décrivant les situations de défaut de capteurs, d'actionneurs ou de dommages sur les composants du système. Ainsi, le fonctionnement global du système peut être décrit par un ensemble de modèles que l'on peut quelques fois réunir dans une structure multimodèles.

Durant ces dernières années, l'approche par multimodèles s'est popularisée et a été largement utilisée pour l'estimation [Maybeck, 1987], la commande [Murray-Smith, 1997] ainsi que pour la modélisation [Gasso, 1999] ; elle est également utilisée par la méthode IMM.

L'approche IMM a été appliquée avec succès dans le domaine du suivi de trajectoire d'une cible où il y a des changements fréquents dans le comportement du système [Bar-Shalom, 1993]. Elle s'appuie sur

l'utilisation d'un banc de filtres disposés en parallèle, chaque filtre étant calé sur un modèle local associé à un comportement particulier du processus réel. De l'évaluation des résidus des filtres, on peut détecter le modèle actif et donc détecter les défauts si ceux-ci sont représentés par des modèles appropriés.

Pour mieux comprendre le fonctionnement de la technique IMM utilisant des filtres de Kalman, nous proposons dans le deuxième paragraphe une brève présentation de cette méthode. Dans le troisième paragraphe, nous montrons l'application de la technique IMM au diagnostic dans le cas d'un seul modèle de bon fonctionnement et de plusieurs modèles de défaut. Le quatrième paragraphe permet d'énoncer une méthode originale que nous avons intitulée « méthode de glissement » d'un groupe de modèles à un autre, dans le but de limiter le nombre de filtres tout en augmentant le nombre de modèles représentant le système ; ceci a un certain intérêt du point de vue temps de calcul et précision sur les modèles et donc améliore la précision de l'estimation. Dans la cinquième partie, on propose une application de la méthode de glissement ainsi qu'une étude de ses performances. Finalement, on conclut sur l'application de la technique IMM au diagnostic et sur les techniques proposées.

2. La technique IMM

Cette partie est consacrée à la présentation des différentes étapes de la technique IMM. L'algorithme est résumé par la table 1 et la figure 1.

Le système observé évolue par sélection d'un modèle parmi r modèles linéaires avec des basculements d'un modèle à un autre régis suivant une chaîne de Markov de matrice Π . On suppose que les r modèles décrivent tous les modes de fonctionnement du système. Le modèle j est décrit par :

$$\begin{cases} \mathbf{x}(k) = \mathbf{F}_j(k)\mathbf{x}(k-1) + \mathbf{G}_j(k)\mathbf{u}(k-1) + \mathbf{v}(k-1) \\ \mathbf{y}(k) = \mathbf{H}_j(k)\mathbf{x}(k) + \mathbf{w}(k) \end{cases} \quad (1)$$

où $\mathbf{x}(k)$ est le vecteur d'état à l'instant k , $\mathbf{F}_j(k)$ est la matrice d'état, $\mathbf{u}(k)$ est l'entrée à l'instant k , $\mathbf{G}_j(k)$ est la matrice des gains de l'entrée, $\mathbf{H}_j(k)$ est la matrice des gains de la sortie, $\mathbf{v}(k)$ et $\mathbf{w}(k)$ sont respectivement le bruit d'état et le bruit de mesure et $\mathbf{y}(k)$ est la sortie du système à l'instant k .

L'estimation adaptative multimodèle par la technique IMM consiste à utiliser plusieurs filtres produisant des estimations différentes pour chaque modèle local, puis à s'appuyer sur ces estimations pour générer des résidus.

Ces résidus sont ensuite utilisés pour calculer la probabilité d'activation de chaque modèle en utilisant une fonction de vraisemblance. L'estimation globale de l'état du système est ensuite calculée comme une

pondération des estimations issues des différents filtres. Pour plus de détails, voir [Bar Shalom, 1989], [Watanabe, 1992]. Les étapes de l'algorithme sont résumées ci après.

Interaction	
Probabilité prédite :	$\mu_j(\mathbf{k} + 1 \mathbf{k}) = \sum_i \pi_{ij}\mu_i(\mathbf{k})$
Probabilité mixte :	$\mu_{ij}(\mathbf{k}) = \frac{\pi_{ij}\mu_i(\mathbf{k})}{\mu_j(\mathbf{k} + 1 \mathbf{k})}$
Estimée mixte :	$\hat{\mathbf{x}}_j^0(\mathbf{k} \mathbf{k}) = \sum_i \hat{\mathbf{x}}_i(\mathbf{k} \mathbf{k})\mu_{ij}(\mathbf{k})$
Variance mixte :	$\mathbf{P}_j^0(\mathbf{k} \mathbf{k}) = \sum_i \left[\mathbf{P}_i(\mathbf{k} \mathbf{k}) + \left(\hat{\mathbf{x}}_j^0(\mathbf{k} \mathbf{k}) - \hat{\mathbf{x}}(\mathbf{k} \mathbf{k}) \right) \times \left(\hat{\mathbf{x}}_j^0(\mathbf{k} \mathbf{k}) - \hat{\mathbf{x}}(\mathbf{k} \mathbf{k}) \right)^T \right] \mu_{ij}(\mathbf{k})$
Etat prédit :	$\hat{\mathbf{x}}_j(\mathbf{k} + 1 \mathbf{k}) = \mathbf{F}_j(\mathbf{k})\hat{\mathbf{x}}_j^0(\mathbf{k} \mathbf{k}) + \mathbf{G}_j(\mathbf{k})\mathbf{u}(\mathbf{k})$
Filtrage et calcul des vraisemblances	
Variance prédite :	$\mathbf{P}_j(\mathbf{k} + 1 \mathbf{k}) = \mathbf{F}_j(\mathbf{k})\mathbf{P}_j^0(\mathbf{k} \mathbf{k})\mathbf{F}_j^T(\mathbf{k}) + \mathbf{Q}_j(\mathbf{k})$
Résidu :	$\mathbf{v}_j = \mathbf{y}(\mathbf{k} + 1) - \mathbf{H}_j(\mathbf{k} + 1)\hat{\mathbf{x}}_j(\mathbf{k} + 1 \mathbf{k})$
Variance du résidu :	$\mathbf{s}_j(\mathbf{k} + 1) = \mathbf{H}_j(\mathbf{k} + 1)\mathbf{P}_j(\mathbf{k} + 1 \mathbf{k})\mathbf{H}_j^T(\mathbf{k} + 1) + \mathbf{R}_j(\mathbf{k} + 1)$
Gain du filtre	$\mathbf{K}_j = \mathbf{P}_j(\mathbf{k} + 1 \mathbf{k})\mathbf{H}_j(\mathbf{k} + 1)\mathbf{s}_j^{-1}(\mathbf{k} + 1)$
Etat mis à jour :	$\hat{\mathbf{x}}_j(\mathbf{k} + 1 \mathbf{k} + 1) = \hat{\mathbf{x}}_j(\mathbf{k} + 1 \mathbf{k}) + \mathbf{K}_j\mathbf{v}_j$
Variance mise à jour	$\mathbf{P}_j(\mathbf{k} + 1 \mathbf{k} + 1) = \mathbf{P}_j(\mathbf{k} + 1 \mathbf{k}) - \mathbf{K}_j\mathbf{s}_j(\mathbf{k} + 1)\mathbf{K}_j^T$
Fonction de vraisemblance	$L_j(\mathbf{k} + 1) = \sqrt{\frac{1}{2\pi \mathbf{s}_j(\mathbf{k}) }} \exp\left(-\frac{1}{2}\mathbf{v}_j\mathbf{s}_j^{-1}(\mathbf{k})\mathbf{v}_j^T\right)$
Actualisation des probabilités d'activation	
Probabilité :	$\mu_j(\mathbf{k} + 1) = \frac{\mu_j(\mathbf{k} + 1 \mathbf{k})L_j(\mathbf{k} + 1)}{\sum_i \mu_i(\mathbf{k} + 1 \mathbf{k})L_i(\mathbf{k} + 1)}$
Estimation globale	
Estimée globale	$\hat{\mathbf{x}}(\mathbf{k} + 1 \mathbf{k} + 1) = \sum_i \hat{\mathbf{x}}_i(\mathbf{k} + 1 \mathbf{k} + 1)\mu_i(\mathbf{k} + 1)$
Variance globale :	$\mathbf{P}(\mathbf{k} + 1 \mathbf{k} + 1) = \sum_j \left[\mathbf{P}_j(\mathbf{k} + 1 \mathbf{k} + 1) + \left(\hat{\mathbf{x}}(\mathbf{k} + 1 \mathbf{k} + 1) - \hat{\mathbf{x}}_j(\mathbf{k} + 1 \mathbf{k} + 1) \right) \left(\hat{\mathbf{x}}_j(\mathbf{k} + 1 \mathbf{k} + 1) - \hat{\mathbf{x}}_j(\mathbf{k} + 1 \mathbf{k}) \right)^T \right] \mu_j(\mathbf{k} + 1)$

Table 1. Technique IMM




Figure 1. Technique IMM

3. Détection de défaut par IMM

L'évolution temporelle de la probabilité d'activation des modèles, calculée par la technique IMM, permet de repérer les modifications du système qui peuvent survenir en cours de fonctionnement. L'analyse de ces probabilités permet de détecter les défauts. Plusieurs règles de décision peuvent être employées.

Règle 1 : prise en compte de la probabilité d'activation la plus importante

$$i(k) = \arg \max_j \mu_j(k)$$

$\mu_i(k) \geq \delta$ le modèle i est actif à l'instant k

$\mu_i(k) < \delta$ le modèle i est inactif à l'instant k

Règle 2 : prise en compte du « contraste » entre les deux probabilités les plus importantes :

$$\begin{cases} i_1(k) = \arg \max_j \mu_j(k) \\ i_2(k) = \arg \max_{j \neq i_1} \mu_j(k) \end{cases}$$

$$\mu_j(k) = \frac{\mu_{i_1}(k)}{\mu_{i_2}(k)}$$

$\mu_i(k) \geq \delta$ le modèle i est actif à l'instant k

$\mu_i(k) < \delta$ le modèle i est inactif à l'instant k

Modèle de défaut

Un défaut d'actionneur peut être modélisé par la modification d'une colonne de la matrice de commande G . Ainsi, un défaut du $i^{\text{ème}}$ actionneur est pris en compte en écrivant le système sous la forme :

$$x(k+1) = Fx(k) + (G + M_i)u(k) + v(k)$$

où M_i est une matrice qui a la même dimension que G et dont toutes les composantes sont nulles sauf celles de la $i^{\text{ème}}$ colonne qui caractérise le défaut sur le $i^{\text{ème}}$ actionneur.

De la même manière, on peut décrire un défaut de capteur par :

$$y(k) = (H + L_i)x(k) + w(k)$$

où L_i est une matrice qui a la même dimension que H et dont toutes les composantes sont nulles sauf celles de la $i^{\text{ème}}$ ligne qui caractérise le défaut sur le $i^{\text{ème}}$ capteur.

Pour l'application de la méthode proposée, on considère un modèle de fonctionnement normal (F_1, G_1, H_1), un modèle de défaut d'actionneur (F_2, G_2, H_2) et un modèle de défaut de capteur (F_3, G_3, H_3), les différentes matrices étant définies par :

$$\begin{aligned} F_1 &= \begin{bmatrix} 0.3 & 0.1 \\ 0.1 & 0.8 \end{bmatrix} & G_1 &= \begin{bmatrix} 0.4 \\ -0.1 \end{bmatrix} & H_1 &= \begin{bmatrix} 1 & 1 \end{bmatrix} \\ F_2 &= \begin{bmatrix} 0.3 & 0.1 \\ 0.1 & 0.8 \end{bmatrix} & G_2 &= \begin{bmatrix} 0.4 \\ 0 \end{bmatrix} & H_2 &= \begin{bmatrix} 1 & 1 \end{bmatrix} \\ F_3 &= \begin{bmatrix} 0.3 & 0.1 \\ 0.1 & 0.8 \end{bmatrix} & G_3 &= \begin{bmatrix} 0.4 \\ -0.1 \end{bmatrix} & H_3 &= \begin{bmatrix} 0 & 1 \end{bmatrix} \end{aligned}$$

Pour tester la méthode, le scénario suivant a été établi : initialement le système est en bon fonctionnement, puis à l'instant 100, survient un défaut sur l'actionneur, à l'instant 133 le système revient au mode de bon fonctionnement et à l'instant 200 un défaut sur le capteur est introduit, puis on revient à nouveau, à l'instant 233, au mode de bon fonctionnement (les séquences d'entrée et de sortie sont visualisées à la figure 4).

Les résultats sont présentés à la figure 2 où l'on constate clairement les changements de régime ; la probabilité d'activation des modèles actifs dans leur zones de fonctionnement respectif fluctue autour de un et donc une détection du défaut est réalisée. Le premier graphe de la figure 2 montre bien que le système est en bon fonctionnement sauf sur les intervalles [100,133] et [200,233] où la fonction μ_1 est sensiblement nulle ; dans ces deux intervalles, l'augmentation de μ_2 ou de μ_3 témoigne des passages du système aux deux régimes de mauvais fonctionnement simulés. La figure 3 représente les erreurs d'estimation sur les états du système et l'on peut constater que la méthode présente de bonnes performances au niveau de l'estimation d'état.




Figure 2. Probabilité d'activation des modèles.




Figure 3. Erreurs d'estimation.




Figure 4. Entrée et sortie du système.

4. Méthode de séquence glissante de modèles

Nous avons élaboré une méthode originale de diagnostic procédant par glissement d'un ensemble de modèles à un autre ensemble de modèles ; cela permet de diminuer considérablement le nombre de modèles actifs, à un instant donné, utilisés dans les techniques IMM ou GPB1 [Bar-Shalom, 1993] et donc de diminuer le temps de calcul. Cette réduction de temps de calcul peut être mise à profit pour augmenter le nombre de modèles locaux et donc augmenter la précision globale du modèle du système.

Dans un premier temps, nous choisissons un ensemble initial de modèles qui représente tous les cas possibles de fonctionnement du système. Ensuite, on considère un sous-ensemble particulier constitué d'un nombre impair de modèles. Dans notre cas, ce sous-ensemble est composé de trois modèles.

Lors du déroulement de l'algorithme, on fait évoluer la structure du sous-ensemble actif selon l'évolution des probabilités d'activation des modèles. Cette évolution est représentée sur la figure 5 où, à l'instant t , le sous-ensemble utilisé est constitué des modèles (M_2 M_3 M_4), puis à l'instant $t+1$ des modèles (M_3 M_4 M_5).

A partir de la probabilité d'activation des modèles du sous-ensemble à l'instant t , on détermine le prochain sous-ensemble de modèles qui servira pour l'itération suivante de l'algorithme. On détermine le modèle le plus probable et on analyse sa position dans le triplet : si c'est le centre du triplet, on garde le même triplet, si le modèle le plus probable est celui de gauche, on décale le centre du triplet vers la gauche et si c'est celui de droite, on décale le centre du triplet vers la droite. La stratégie se formalise de la façon suivante :

A l'instant t , on note la séquence de modèles $S_t = (M_{k-1} \ M_k \ M_{k+1})$

On détermine le modèle actif :

$j = \arg \max (\mu_{k-1}, \mu_k, \mu_{k+1})$

Si $j = k-1$, la nouvelle séquence est définie par $S_{t+1} = (M_{k-2} \ M_{k-1} \ M_k)$ et on réinitialise les μ (voir organigramme figure 6).

Si $j = k$, la séquence n'est pas modifiée :

$$S_{t+1} = S_t.$$

Si $j = k+1$, la nouvelle séquence est définie par $S_{t+1} = (M_k \ M_{k+1} \ M_{k+2})$, on réinitialise également les μ (voir organigramme figure 6).




Figure 5. Glissement d'un sous-ensemble de modèles à un autre sous-ensemble

Application

Nous avons appliqué cette stratégie à un système représenté par sept modèles :

$M_1, M_2, \dots, M_7$.

$$\begin{cases} x(k) = F_j x(k-1) + G_j u(k-1) + v(k-1) \\ y(k) = H_j x(k) + w(k), \text{ où } j = 1..7 \end{cases}$$

Les matrices de ces modèles sont :

$$G_j = [0.4 \ -0.1]^T \quad H_j = [0.4 \ -0.1]$$

$$F_1 = \begin{bmatrix} 0.3 & 0.1 \\ 0.1 & 0.8 \end{bmatrix} \quad F_2 = \begin{bmatrix} 0.4 & 0.1 \\ 0.1 & 0.85 \end{bmatrix}$$

$$F_3 = \begin{bmatrix} 0.5 & 0.1 \\ 0.1 & 0.87 \end{bmatrix} \quad F_4 = \begin{bmatrix} 0.6 & 0.1 \\ 0.1 & 0.89 \end{bmatrix}$$

$$F_5 = \begin{bmatrix} 0.7 & 0.1 \\ 0.1 & 0.9 \end{bmatrix} \quad F_6 = \begin{bmatrix} 0.78 & 0.1 \\ 0.1 & 0.92 \end{bmatrix}$$

$$F_7 = \begin{bmatrix} 0.83 & 0.1 \\ 0.1 & 0.94 \end{bmatrix}.$$

Dans un premier temps, pour tester la méthode proposée, nous considérons le scénario d'un passage du modèle M_k vers le modèle M_{k+1} (test 1) tout les cent pas d'échantillonnage en partant du modèle M_1 jusqu'au modèle M_7 .




Figure 6. Etapes de la méthode de glissement

On retrouve de façon satisfaisante la probabilité d'activation de chaque modèle par l'algorithme d'estimation. On évalue la qualité de la méthode proposée en utilisant un critère de bonne détection au cours d'une simulation de type Monte Carlo. Une estimation est déclarée satisfaisante si les deux critères suivants sont satisfaits :

- la moyenne de la probabilité d'activation de chaque modèle, sur la période où il est effectivement actif supérieure à **90%**,
- sur la période où un modèle, est est actif, la probabilité d'activation de ce modèle est supérieure à la probabilité d'activation des autres modèles dans plus de **90%** des cas.

Pour 10000 simulations, on a enregistré un taux de réussite de **98,1%** ce qui est important pour un critère aussi sélectif. Les moyennes des probabilités d'activation de chaque modèle, calculées sur les 10000 simulations, sont représentées sur la figure 7.

Dans un deuxième temps, on introduit dans le scénario un saut du modèle M_3 vers le modèle M_5 sans passer par le modèle M_4 (test 2) ; on évalue la pertinence de la méthode de détection suivant le même critère.

Pour 10000 simulations, on a un taux de réussite de **87,58%** ce qui est bon vu l'importance de la discontinuité introduite dans le scénario ; les moyennes des probabilités d'activation de chaque modèle sont représentées sur la figure 8.

Enfin, pour le dernier test (test 3), on génère une sortie à partir des modèles $M_1, M_2, M_3, M_5, M_6, M_7$ et un modèle intermédiaire entre M_4 et M_5 noté $M_{4,5}$

$$\text{de matrice d'état : } F_{4,5} = \begin{bmatrix} 0.65 & 0.1 \\ 0.1 & 0.895 \end{bmatrix}$$

Les probabilités d'activation des différents modèles sont représentées à la figure 9. On remarque que dans la période où le modèle $M_{4,5}$ est actif, les modèles M_4 et M_5 se partagent la probabilité mais que cela n'affecte pas la probabilité d'activation des autres modèles.




Figure 7. Moyenne des probabilités de chaque modèle (test 1).




Figure 8. Moyenne des probabilités de chaque modèle (test 2).




Figure 9. Moyenne des probabilités de chaque modèle (test 3).

Conclusion

Dans cet article, nous avons tout d'abord montré l'application d'un algorithme d'estimation basé sur l'utilisation d'un multimodèle (IMM) à la détection de défaut dans le cas d'un système linéaire (avec un seul modèle de bon fonctionnement) ; les résultats obtenus montrent l'efficacité de cette méthode pour la détection et l'estimation d'état. Cependant, cette méthode présente des restrictions quant au nombre de modèles ; quand ce nombre augmente, la dispersion des probabilités d'activation des modèles augmente et la méthode éprouve des difficultés à distinguer le modèle actif. Pour résoudre ce problème, nous avons proposé la méthode de glissement qui permet l'utilisation d'un plus grand nombre de modèles pour caractériser le système et donc une meilleure précision sur les modèles tout en palliant au problème de la dispersion des probabilités d'activation ce qui est intéressant dans le cas des systèmes non linéaires ou des systèmes hybrides. Les résultats obtenus par une simulation de type Monte Carlo sont très satisfaisants malgré des critères exigeants.

Bibliographie

Ackerson G.A., Fu K.S. On state estimation in switching environment. *IEEE Transactions on Automatic Control*, 15 (1), p. 10-17, 1970.

Bar-Shalom Y., Chang K.C., Blom H.A. Tracking a manoeuvring target using input estimation versus interacting multiple model algorithm. *IEEE Transactions on Aerospace and Electronics Systems*, AES-25 (2), p. 296-300, 1989.

Bar-Shalom Y. Multitarget-multisensor tracking : advanced applications. Artech House, 1990.

Bar-Shalom Y., Li X. Estimation and tracking : principles, technique, and software. Artech House, 1993.

Ding Z., Hong L. A distributed IMM fusion algorithm for multi-platform tracking. *Signal Processing*, 64, p. 167-176, 1998.

Ding Z., Hong L. An interacting multiple model algorithm with a switching Markov chain. *Mathematics Computer Modelling*, p. 1-9, 1997.

Gasso K., Mourot G., Ragot J. Structure identification in multiple model representation : elimination and merging of local models. *Proceedings of the 40th Conference on Decision and Control*, Orlando, 2001.

Hanlon P.D., Maybeck P.S. Characterization of Kalman filter residuals in the presence of mismodeling. *IEEE Transactions on Aerospace and Electronics Systems*, 36 (1), p. 114-131, 2000.

Maybeck P.S., Hentz K. Investigation of moving-bank multiple model adaptive algorithms. *AIAA Journal of Guidance, Control and Dynamics*, 10, p. 90-96, 1987.

Mihaylova L. State estimation by IMM filter in the presence of structural uncertainty. *Recent advances in signal processing and communications*, Engineering Society Press (Greece), p. 83-88, 1999.

Patton R., Frank P.M. Clark R. Fault diagnosis in dynamic systems. Prentice Hall, 1989.

Watanabe K. Adaptive estimation and control : partitioning approach. Prentice Hall, 1992.

Zhang Y., Li X.R. Detection and diagnosis of sensor and actuator failures using IMM estimator. *IEEE Transactions on Aerospace and Electronics Systems*, 34 (4), p. 1293-1313, 1998.