

Une approche basée sur des données mixtes – mesures et estimations – pour la détection de défaillances d’un système robotisé

Rabah Mazouzi*, Rabih Taleb*, Lynda Seddiki*
Cyril De Runz**, Kevin Guelton**, Herman Akdag*

*LIASD, Université Paris 8, 2 rue de la Liberté - 93526 Saint-Denis cedex
rabah@ai.univ-paris8.fr, rtaleb@ai.univ-paris8.fr,
lynda.seddiki@ai.univ-paris8.fr, herman.akdag@ai.univ-paris8.fr
<http://www.ai.univ-paris8.fr/>

**CReSTIC EA 3804, Université de Reims Champagne-Ardenne,
Moulin de la Housse BP 1039 - 51687 Reims Cedex 2
cyril.de-runz@univ-reims.fr, kevin.guelton@univ-reims.fr
<http://crestic.univ-reims.fr/>

Résumé. Mettre en place un dispositif de détection de pannes représente de nos jours l’un des défis majeurs pour les constructeurs des systèmes robotisés. Le processus de détection nécessite l’utilisation d’un certain nombre de capteurs afin de surveiller le fonctionnement de ces systèmes. Or, le coût ainsi que les contraintes liées à la mise en place de ces capteurs conduisent souvent les concepteurs à optimiser leurs nombres, ce qui mène à un manque de mesures nécessaires pour la détection de défaillances. L’une des méthodes pour combler ce manque est d’estimer les paramètres non mesurables à partir d’un modèle mathématique décrivant la dynamique du système réel. Cet article présente une approche basée sur des données mixtes (données mesurées et données estimées) pour la détection de défaillances dans les systèmes robotisés. Cette détection est effectuée en utilisant un classifieur de type arbre de décision. Les données utilisées pour son apprentissage proviennent des mesures prises sur le système réel. Ces données sont ensuite enrichies par des données estimées en provenance d’un observateur basé sur un modèle analytique. Cet enrichissement sous forme d’attributs supplémentaires a pour but d’augmenter la connaissance du classifieur sur le fonctionnement du système et par conséquent améliorer le taux de bonne détection de défaillances. Une expérience sur un système d’actionnement d’un siège robotisé, montrant l’intérêt de notre approche, sera présentée à la fin de l’article.

1 Introduction

La maintenance des systèmes industriels robotisés est une tâche de plus en plus fastidieuse et coûteuse. Des outils de sûreté de fonctionnement (sécurité, fiabilité, surveillance, etc.) ont

donc été développés et mis en place afin d'assurer la disponibilité ainsi que le fonctionnement normal des processus. La communauté des chercheurs s'intéresse de plus en plus aux méthodes de surveillance, autrement dit les méthodes de détection de défaillances ou encore les méthodes de diagnostic dans le cas général, qui consistent à détecter, localiser et identifier les défaillances pouvant survenir sur un système. Ces méthodes se regroupent en deux grandes familles, à base de modèles mathématique (Isermann, 2011; Ding, 2013; Bouibed et al., 2014) et à base de données (Vaija et al., 1986; Ondel, 2006; Narvaez, 2007).

La première famille – à base de modèles – est généralement utilisée dans le cas d'une connaissance suffisante du fonctionnement interne du système ainsi que de ses paramètres physiques, ces méthodes peuvent donc représenter fidèlement le fonctionnement d'un système robotisé qui peut conduire à mettre en place des capteurs logiciels, représentés par des observateurs d'états (Luenberger, 1964; Isermann, 1984), afin de résoudre les problèmes liés aux problèmes de coût, d'encombrement ou autre.

La deuxième famille – à base de données – est fondée sur l'exploitation des données récupérées d'un système robotisé ou de simulation que ce soit en fonctionnement normal ou en cas de défaillances. Cette famille de détection de défaillances n'entraîne pas de contraintes supplémentaires pour traiter des systèmes complexes analytiquement sauf qu'elle a un inconvénient majeur c'est qu'on a besoin de l'alimenter par une base de données et un historique d'expériences suffisants, ce qui nécessite un temps de calcul important et une mémoire de stockage élevée ainsi qu'un nombre élevé de capteurs (Venkatasubramanian et al., 2003).

Concevoir un dispositif capable de détecter et de diagnostiquer une panne, voire la prévoir, avant qu'elle survienne est une solution qui peut faciliter et améliorer les tâches de maintenance. Or ces méthodes de diagnostic souffrent de plusieurs problèmes : taux d'erreur élevé, insuffisance d'attributs ou de paramètres d'entrées, etc. Par ailleurs, il faut savoir qu'aucune des méthodes de diagnostic ne répond à tous les critères que l'on souhaite avoir dans un système de détection de défaillances à cause de l'absence de la connaissance totale des entrées et des sorties ainsi que leurs interactions avec l'environnement de travail du système, d'où l'intérêt de combiner ces deux approches. Or, très peu de travaux traitent d'une telle combinaison (Narasimhan et al., 2010; Schubert et al., 2011).

Narasimhan et al. (2010) ont présenté une approche qui utilise les modèles mathématiques (analytiques) pour les défaillances électriques, mécaniques et thermiques en combinaison avec un classifieur basé sur les caractéristiques obtenues à partir des données de vibrations d'un actionneur électromécanique. L'approche proposée ne déclenche l'extraction des données que lorsque nécessaire afin de minimiser la taille de leur base de données. Or, la construction de l'arbre de décision se fait hors ligne afin de réduire le temps de calcul mais influence la qualité des résultats obtenus.

Schubert et al. (2011) ont proposé une approche de diagnostic basée sur la combinaison d'une méthode à base de modèle avec des méthodes à base de données. Cette approche consiste à fusionner des approches statistiques telles que les méthodes de contrôle statistiques univariées avec un observateur à entrées inconnues afin de détecter et de localiser les défaillances. A savoir que cette approche n'est pas performante pour détecter les défaillances qui varient au cours du temps ou présentant des fortes non-linéarités.

Le travail que nous présentons dans cet article décrit une approche de détection de défaillances en utilisant un classifieur 'Random tree' pour son apprentissage, ce classifieur utilise des attributs provenant de deux sources différentes : une série de mesures expérimentales sur le

système robotisé et une série d'estimations avec un modèle analytique représentant le fonctionnement du système robotisé avec un observateur d'état. Cette approche d'estimation a pour but de fournir les estimations des variables non mesurables sur le système afin d'enrichir la base d'apprentissage avec des attributs supplémentaires.

Cet article est structuré de la manière suivante. La deuxième partie est dédiée à la description de notre problématique dans son contexte industriel. Dans la troisième partie nous décrivons l'approche de détection de défaillances proposée. Une expérimentation pour la détection de défaillances sur un système d'actionnement d'un siège robotisé sera présentée dans la quatrième partie. La dernière partie donnera la conclusion et les perspectives de ce travail.

2 Cadre d'étude

Cette étude porte sur la détection de défaillances à l'aide d'une classification automatique. Dans cette section, nous présentons notre contexte industriel. Nous avons, d'une part, le système robotisé et les capteurs associés fournissant les données mesurées, et, d'autre part, les données fournies par un observateur d'état et estimées à l'aide de modèles mathématiques.

2.1 Le système robotisé

Il s'agit d'un système d'actionnement d'un siège robotisé, composé des actionneurs et des capteurs. Ces derniers ont pour but de fournir les paramètres physiques mesurables (tension, courant, ... etc) suite à des couples de commande appliqués par les actionneurs sur le corps du siège.

Ce corps du siège est composé de trois parties principales : le dossier, l'assise et repose-jambes (cf. figure 1). Un boîtier de commande électronique envoie des commandes, en fonction de consignes utilisateurs (monter, descendre, avancer, reculer, etc.), aux différents actionneurs afin de mettre en mouvement le siège.

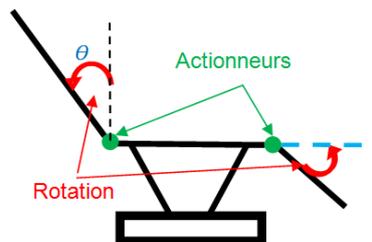


FIG. 1 – *Système robotisé (siège)*

Dans notre cas, on étudie plus particulièrement la partie du dossier du siège qui est modélisé par un simple pendule inversé et alimenté par un actionneur électrique. Ce système a donc des entrées électriques comme la tension d'alimentations de l'actionneur, le courant consommé par ce dernier, etc. qui sont mesurables. Quant à ses variables, ce sont des variables de types : position et vitesse angulaires ($\theta, \dot{\theta}$) dont seulement la position est mesurée. On cherche donc

Une approche basée sur des données mixtes pour la détection de défaillances

à estimer la vitesse angulaire du dossier ($\dot{\theta}$) à partir d'un observateur d'état qui sera présenté dans le paragraphe suivant.

2.2 L'observateur

Dans cette partie, nous abordons l'observateur d'état (cf. figure 2). Ce dernier consiste à estimer les états non mesurables à partir d'un modèle dynamique représentant le système robotisé, à partir de la mesure de ses entrées-sorties.

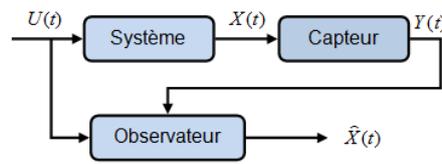


FIG. 2 – Observateur

Le modèle dynamique est obtenu à partir du formalisme Lagrangien qui décrit le mouvement d'un système mécanique en utilisant des équations liant ses entrées (couples et/ou forces appliqués aux actionneurs) à ses sorties (positions, vitesses et accélérations articulaires) (Khalil et Dombre, 1999; Siciliano et Khatib, 2008).

Le modèle dynamique du dossier est présenté par l'équation ci-dessous :

$$J\ddot{\theta}(t) - mgl \sin \theta(t) = u(t) \quad (1)$$

$J=0,0108 \text{ kg.m}^2$, $m=0,7 \text{ kg}$, $l=0,33 \text{ m}$ et $\ddot{\theta} \text{ (m/s}^2\text{)}$ sont respectivement le moment d'inertie, la masse, la longueur et l'accélération angulaire du pendule inversé. L'accélération de pesanteur est donnée par $g=9,81 \text{ (m/s}^2\text{)}$. $u(t)$ représente le couple moteur appliqué ($N.m$)

Ce modèle dynamique est donc linéarisé autour du point de fonctionnement '0', en utilisant le développement de Taylor, afin d'obtenir la représentation d'état linéaire à temps continu suivante :

$$\begin{cases} \dot{x}(t) &= Ax(t) + Bu(t) \\ y(t) &= Cx(t) \end{cases} \quad (2)$$

Le vecteur d'état dans notre cas est composé de la position et la vitesse angulaires, il s'écrit donc de la façon suivante :

$$x(t) = \begin{bmatrix} \theta(t) \\ \dot{\theta}(t) \end{bmatrix} \quad (3)$$

La représentation d'état d'un observateur d'état prend la forme suivante (Luenberger, 1964) :

$$\begin{cases} \dot{\hat{x}}(t) &= A\hat{x}(t) + Bu(t) + L(y(t) - \hat{y}(t)) \\ \hat{y}(t) &= C\hat{x}(t) \end{cases} \quad (4)$$

Pour le système du dossier, nous avons les matrices suivantes :

$$A = \begin{bmatrix} 0 & 1 \\ 287.45 & 0 \end{bmatrix}, B = \begin{bmatrix} 0 \\ 92.94 \end{bmatrix}, C = [1 \quad 0] \quad (5)$$

x , u et y représentent respectivement les vecteurs d'états, d'entrée et de sortie.

\hat{x} et \hat{y} sont les vecteurs d'états estimés et de sortie estimés.

$A \in \mathbb{R}^{n \times n}$, $B \in \mathbb{R}^{n \times m}$, $C \in \mathbb{R}^{p \times m}$.

De même, les matrices A , B , C et L représentent respectivement les matrices d'état, d'entrée, de sortie, et la matrice de gain d'observateur. Cette matrice de gain est obtenue par la méthode de placement de pôles en choisissant les pôles désirés qui doivent être placés à partie réelle négative (Luenberger, 1971). Dans notre cas les pôles désirés sont -5 et -1, on obtient donc la matrice de gain suivante $= [6; 215,5]$.

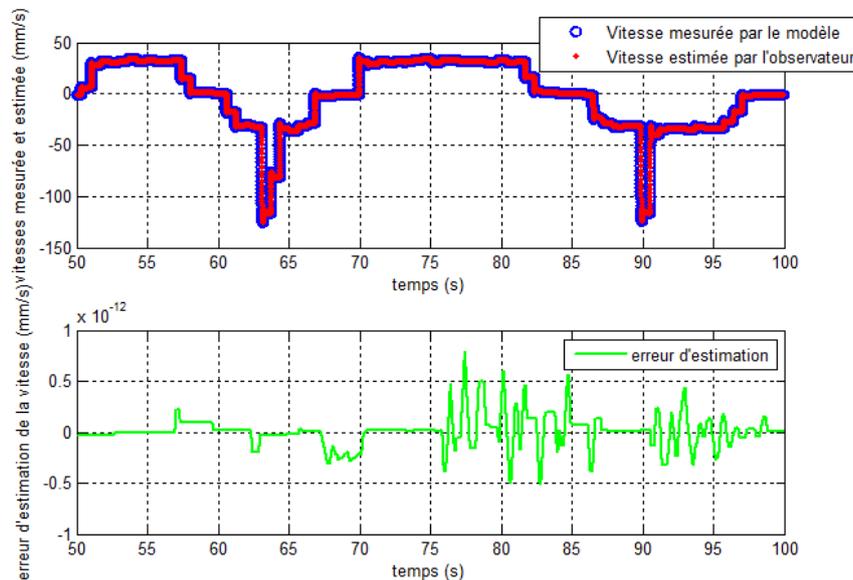


FIG. 3 – estimation de la vitesse angulaire

A l'aide de cet observateur et de nos données de capteurs, nous cherchons à estimer la vitesse angulaire du dossier ($\dot{\theta}$) et donc à détecter au mieux les défaillances. La figure 3 présente la vitesse angulaire du dossier simulée à partir du modèle dynamique et celle estimée par l'observateur. Quant à la courbe verte, elle montre l'erreur d'estimation entre la variable simulée et celle estimée. La simulation du modèle ne permet pas l'estimation de la vitesse dans la mesure où l'on ne connaît pas, à priori, les conditions initiales. C'est pourquoi un observateur d'état est mis en place. En effet, celui-ci permet d'estimer les grandeurs non mesurées (la vitesse en l'occurrence) tout en garantissant la convergence de l'erreur d'estimation entre les variables estimées et les variables réelles (non mesurables). Cela explique la faible valeur de l'erreur d'estimation qui est de l'ordre de $5 \cdot 10^{-13}$, ce qui garantit la fiabilité de l'estimation de l'observateur d'état utilisé. Notre approche est présentée dans la partie suivante.

3 Approche proposée

L'idée principale de notre approche est d'enrichir des données d'apprentissage d'un classifieur utilisé pour la détection de défaillances en ajoutant certains attributs pour renforcer l'apprentissage automatique. Cet enrichissement est obtenu à l'aide des données estimées provenant d'un modèle mathématique qui décrit le mouvement dynamique et le fonctionnement du système. Nous avons donc utilisé l'observateur d'état défini précédemment afin d'estimer la vitesse angulaire, ce qui nous permettra d'obtenir un attribut supplémentaire.

La figure 4 montre les différentes étapes de traitement de données destinées à l'apprentissage du classifieur :

- Le système robotisé équipé des différents capteurs qui fournissent les données réelles mesurées,
- L'observateur d'état qui décrit le fonctionnement du système et qui est capable de fournir des estimations de certaines variables non mesurables,
- La mise en forme des données,
- Le modèle d'apprentissage (arbre de décision),
- Le classifieur de détection (à embarquer sur le système robotisé).

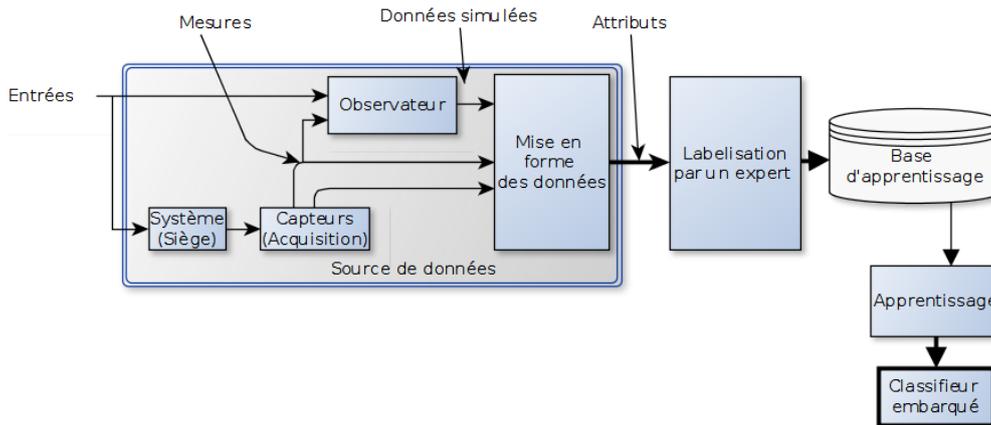


FIG. 4 – Traitement de données et apprentissage du classifieur

3.1 Mise en forme des données

Dans cette section nous décrivons le processus de traitement de données de l'acquisition jusqu'à la forme finale utilisée pour l'apprentissage et la classification.

3.1.1 Données mesurées (Acquisition)

Les mesures sont des données brutes enregistrées d'une manière cyclique à un intervalle de temps (300 ms) représentant les différents capteurs installés sur le siège. Un regroupement

de ces mesures est effectué de sorte que chaque instance représente une action de l'utilisateur (montée, descente, stop, etc.), pendant cette action plusieurs valeurs en provenance des capteurs ont été enregistrées. Ces valeurs sont des grandeurs physiques, un pré-traitement de ces grandeurs est nécessaire afin d'obtenir des indicateurs d'un fonctionnement normal ou un dysfonctionnement du mouvement du siège.

3.1.2 Création d'attributs

Le couple appliqué sur l'actionneur du système robotisé sera injecté en entrée du modèle analytique, produisant à partir de l'observateur les estimations des grandeurs non mesurables qui seront utilisées par la suite pour rajouter d'autres attributs à chaque instance.

L'un des attributs les plus importants est la position angulaire. Cette position va permettre au classifieur de déterminer si le mouvement correspond, ou non, aux différentes valeurs en entrées du système (couple, courant ... etc). Une autre variable importante est la vitesse angulaire. Grâce à cette variable, on peut savoir si le mouvement est correct ou pas. un blocage mécanique, glissement, ou mouvement irrégulier peut facilement influencer la valeur de la vitesse angulaire. Or, on ne dispose pas de capteur qui mesure cette variable, d'où l'intérêt de l'estimer afin d'améliorer la détection de défaillances. Cet attribut est estimé à partir de l'observateur d'état ainsi que des attributs mesurés sur le siège robotisé.

Un dysfonctionnement récurrent sur le siège robotisé est l'irrégularité de mouvement, en effet une partie du siège (le dossier par exemple) peut emprunter une trajectoire irrégulière lors de son mouvement. Pour cela nous avons défini un indicateur de dispersion des points représentant les positions par rapport à une droite qui représente un mouvement correct peut déterminer s'il y a eu, ou non, une irrégularité de mouvement. Cet indicateur est utilisé comme attribut supplémentaire dans les données d'apprentissage. Il est obtenu à l'aide d'un post-traitement de certaines données mesurées (la durée et la position angulaire).

Le tableau 1 montre différents exemples d'instances avec les différents attributs de la base d'apprentissage. Ces exemples sont aussi illustrés dans la figure 5.

	Action	Durée (<i>ms</i>)	Position (<i>pas</i>)	I_d (<i>mA</i>)	I_s (<i>mA</i>)	I_f (<i>mA</i>)	Régularité du mouvement	Vitesse (<i>mm/s²</i>) (<i>estimée</i>)	Classe
(a)	01	13730	-399	152	206	2	0.9983	-26,9	N
(b)	02	13507	399	330	250	142	0.9991	28,9	N
(c)	01	5848	-97	140	58	-18	0.9798	-15,1	I
(d)	02	9653	282	310	1100	120	0.9991	28,8	S
(e)	01	8358	-328	140	80	-11	0.9626	-37,6	G
(f)	01	15433	-158	160	126	0	0.6171	9,9	B

TAB. 1 – Exemples d'instances

I_d : Courant de départ, I_s : Courant stable, I_f : Courant de freinage.

N : Normale ; I : Irrégularité ; S : Surconsommation ; G : Glissement ; B : Blocage.

La figure 5 présente différents cas de fonctionnement en traçant les courbes des positions et des courants correspondants. Les deux exemples (a) et (b) présentent une descente en fonctionnement normal suivie par une montée toujours en fonctionnement normal. L'exemple (c)

montre une descente avec un mouvement mécanique irrégulier (mouvement vibratoire). Une surconsommation du courant est illustrée par l'exemple (d). On remarque un mouvement défaillant de type glissement mécanique dans l'exemple (e) et un autre dysfonctionnement de type blocage mécanique dans le dernier exemple (f). Ce type de blocage mécanique se termine par un arrêt complet de l'actionneur pendant quelques secondes afin d'éviter tout type d'échauffement au niveau du moteur électrique.

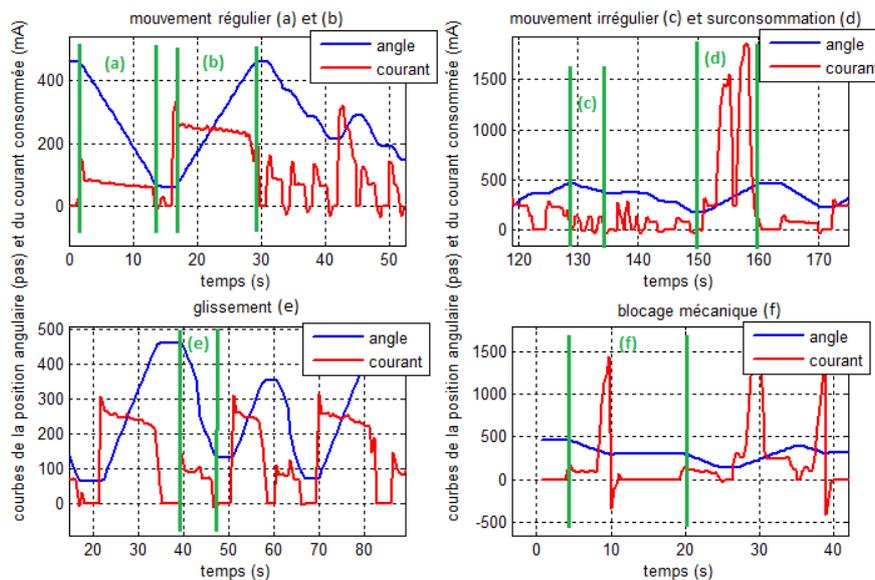


FIG. 5 – Position et courant en fonctionnement normal et défaillant : mouvement régulier, mouvement irrégulier, surconsommation de courant, glissement et blocage

3.1.3 Labellisation

Dans cette étape un expert qui accompagne le processus de mise en forme de données, donne son avis (fonctionnement normal ou défaillant) par rapport à chaque instance en l'étiquetant avec l'observation qu'il a constaté lors de l'acquisition.

3.2 Modèle d'apprentissage et classification

Pour choisir un modèle d'apprentissage on s'est basé sur une étude de la précision de classification sur l'outil WEKA* en utilisant les données d'apprentissage obtenues de l'étape de mise en forme. Une étude comparative de plusieurs classifieurs est présentée dans la partie dédiée aux résultats de l'expérimentation.

*. Weka est une boîte à outils qui contient une collection d'algorithmes d'apprentissage automatique
<http://www.cs.waikato.ac.nz/ml/weka>

Dans l'étape de la classification on utilise la même méthode de mise en forme de données que celle utilisée à l'étape de l'apprentissage (source de données) voir la figure 6 pour produire une instance qui correspond à l'action utilisateur, notre classifieur produit une réponse seulement si elle représente une défaillance, une alerte sera déclenchée.

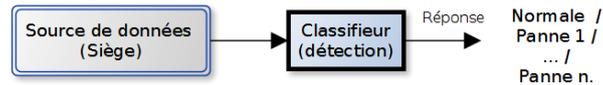


FIG. 6 – Classification

4 Expérimentation

Afin de valider notre approche nous avons réalisé deux séries d'expériences sur l'outil Weka :

- La première série consiste à utiliser, pour données d'apprentissage, uniquement les données avec les attributs issus de mesures ;
- La seconde série exploite à la fois les attributs mesurés et ceux estimés par l'observateur.

4.1 La base d'apprentissage

La base d'apprentissage est constituée de 114 instances réparties, sur les différentes classes, comme suit :

- 97 instances montrant un fonctionnement normal,
- 4 instances de défaillance de type surconsommation électrique,
- 4 instances de défaillance de type blocage,
- 6 instances de défaillance de type glissement mécanique,
- 3 instances de défaillance de type mouvement mécanique irrégulier.

4.2 Résultats

Nous présentons dans le tableau 2 les résultats de l'expérimentation sur nos données en utilisant plusieurs classifieurs dans Weka. Dans ce tableau, les taux de bonne classification sont donnés pour les 5 méthodes testées ayant obtenu les meilleurs taux de bonne classification.

Ces classifieurs sont : J48 qui est l'implémentation sous Weka de l'algorithme d'arbre de décision C4.5 (Quinlan, 1993), Random tree (Witten et Frank, 2005), BayesNet (Bouckaert, 2004), Decision table (Kohavi, 1995), JRip (Fürnkranz et Widmer, 1994).

C4.5 et Random tree sont des algorithmes qui exploitent un arbre de décision c'est à dire un graphe de type arbre dont le parcours jusqu'aux feuilles (décision) dépend des valeurs des différents attributs. Dans Random tree, l'arbre de décision est défini à l'aide d'une régression linéaire et fournit un modèle de régression linéaire par morceau tandis que le C4.5, son implémentation J48, fournit un modèle constant par morceaux.

Une approche basée sur des données mixtes pour la détection de défaillances

BayesNet est un réseau bayésien (autour de probabilités conditionnelles). Enfin, JRip et Decision Table construisent un modèle logique propositionnel autour de nos données. Decision Table utilise les tables de décision afin de représenter les règles.

	<i>Sans attributs estimés</i>	<i>Avec attribut estimé</i>
<i>Classifieur</i>	Taux de bonne classification (%)	Taux de bonne classification (%)
<i>BayesNet</i>	91.2	92.1
<i>Decision table</i>	90.3	92.1
<i>J48</i>	91.2	92.9
<i>JRip</i>	90.3	93.8
<i>Random tree</i>	88.5	93.8

TAB. 2 – Résultats obtenus à partir des classifieurs utilisés

À partir de ces résultats, nous constatons que quelque soit la méthode, les taux de bonne classification sont améliorés suite à l'ajout des deux attributs, un estimé et un calculé, l'apport individuel de chaque attribut a été évalué, la conjugaison des deux donne le gain le plus important : un gain minimum de 0,8% pour BayesNet, un gain maximal de 5,2% pour Random Tree et un gain moyen de 2,6%. Par conséquent la détection de défaillances sera plus efficace. Cela indique aussi que l'ajout des données issues d'un observateur d'état fournissent une véritable plus-value à la caractérisation du fonctionnement du système robotisé.

Nous pouvons choisir l'un des deux classifieurs ayant les meilleurs résultats (un taux de bonne classification de 93.8%). Nous avons opté pour celui de type arbre de décision Random tree (avec le meilleur gain). Il semble le plus adapté à ce genre d'application industrielle. Il détecte parfaitement les défaillances dues à des blocages mécaniques.

Cependant, ce classifieur donne une mauvaise classification de l'ordre de 6,2% ce qui n'est pas négligeable et pourrait être très impactant dans ce type de système. De plus, une étude par classe de défaillance montre que le taux de bonne classification pour les défaillances par vibration est très faible (33%) et les deux tiers restant ont été classés en fonctionnement normal.

La conception de nouvelles méthodes de classification plus performantes (floue ou autre) est donc envisageable afin d'améliorer le taux de bonne classification. Par ailleurs, l'apport pour la qualité de la classification de l'observateur d'état montre que le traitement proposé d'utilisation de données mixtes est pertinent. Les données estimées peuvent être améliorées et enrichies avec d'autres types d'observateurs plus performants (par exemple : observateurs non-linéaires, observateurs à entrées inconnues, etc.).

5 Conclusions et perspectives

Dans cet article, une approche de détection de défaillances, utilisant un classifieur de type arbre de décision basé sur une base de données mixtes, a été proposée. Cette base de données est constituée de deux parties, la première issue des mesures sur un siège robotisé et la deuxième provenant d'un observateur d'état. Ce dernier est basé sur un modèle analytique du siège et estime les grandeurs non mesurables afin d'enrichir cette base de données et d'avoir

des attributs supplémentaires dans le but d'améliorer le taux de bonne détection de défaillances. Une application sur un système d'un siège robotisé a été présentée dans le dernier paragraphe et montre l'intérêt de cette approche dans la détection de défaillances.

L'ajout de l'attribut estimé pour la détection de défaillances dans le cadre d'utilisation de classifieurs donne des meilleurs taux de bonnes classifications. Cela tend à prouver que l'approche proposée pourrait permettre de réduire les coûts industriels de production de capteurs ad-hoc. Cependant, le nombre de mauvaise classification est encore trop important et limite encore le potentiel industriel de notre proposition.

Aussi, nous envisageons d'exploiter le modèle analytique non-linéaire en utilisant un observateur non-linéaire afin d'améliorer les données estimées dans le but d'augmenter la précision du système de classification et d'estimer d'autres paramètres afin de prédire les défaillances et donc mettre en place des solutions de pronostic de pannes.

L'augmentation de la taille du jeu de données est envisageable sous la contrainte de garantir l'équilibre de répartition des données d'apprentissage dans les différentes classes afin d'éviter le sur/sous apprentissage du classifieur.

Enfin, nous travaillerons à l'embarquement des classifieurs sur des systèmes ad-hoc pouvant être intégrés aux systèmes robotisés.

Références

- Bouckaert, R. R. (2004). Bayesian network classifiers in weka. Technical report, University of Waikato, New-Zealand.
- Bouibed, K., L. Seddiki, K. Guelton, et H. Akdag (2014). Actuator and sensor fault detection and isolation of an actuated seat via nonlinear multi-observers. *Systems Science & Control Engineering : An Open Access Journal* 2(1), 150–160.
- Ding, S. X. (2013). *Model-Based Fault Diagnosis Techniques : Design Schemes, Algorithms and Tools*. Springer Science & Business Media.
- Fürnkranz, J. et G. Widmer (1994). Incremental reduced error pruning. In W. W. Cohen et H. Hirsh (Eds.), *Machine Learning, Proceedings of the Eleventh International Conference, Rutgers University, New Brunswick, NJ, USA, July 10-13, 1994*, pp. 70–77. Morgan Kaufmann.
- Isermann, R. (1984). Process fault detection based on modeling and estimation methods - a survey. *Automatica* 20(4), 387–404.
- Isermann, R. (2011). *Fault-diagnosis applications : model-based condition monitoring : actuators, drives, machinery, plants, sensors, and fault-tolerant systems*. Springer Science & Business Media.
- Khalil, W. et E. Dombre (1999). *Modélisation, identification et commande des robots*. Hermès science publ.
- Kohavi, R. (1995). The power of decision tables. In *Proceedings of the European Conference on Machine Learning*, pp. 174–189. Springer Verlag.
- Luenberger, D. G. (1964). Observing the state of a linear system. *IEEE Transactions on Military Electronics* 8(2), 74–80.

- Luenberger, D. G. (1971). An introduction to observers. *IEEE Transactions on automatic control* 16(6), 596–602.
- Narasimhan, S., I. Roychoudhury, E. Balaban, et A. Saxena (2010). Combining model-based and feature-driven diagnosis approaches—a case study on electromechanical actuators. In *21st International Workshop on Principles of Diagnosis*, pp. 1–8.
- Narvaez, C. V. I. (2007). *Diagnostic par techniques d'apprentissage floues : concept d'une méthode de validation et d'optimisation des partitions*. Ph. D. thesis, INSA de Toulouse.
- Ondel, O. (2006). *Diagnostic par reconnaissance des formes : Application à un ensemble convertisseur-machine asynchrone*. Ph. D. thesis, Ecole Centrale de Lyon.
- Quinlan, J. R. (1993). *C4.5 : Programs for Machine Learning*. San Francisco, CA, USA : Morgan Kaufmann Publishers Inc.
- Schubert, U., U. Kruger, H. Arellano-Garcia, T. de Sá Feital, et G. Wozny (2011). Unified model-based fault diagnosis for three industrial application studies. *Control Engineering Practice* 19(5), 479–490.
- Siciliano, B. et O. Khatib (2008). *Springer handbook of robotics*. Springer Science & Business Media.
- Vaija, P., M. Järveläinen, et M. Dohnal (1986). Failure diagnosis of complex systems by a network of expert bases. *Reliability Engineering* 16(3), 237 – 251.
- Venkatasubramanian, V., R. Rengaswamy, S. N. Kavuri, et K. Yin (2003). A review of process fault detection and diagnosis : Part iii : Process history based methods. *Computers & chemical engineering* 27(3), 327–346.
- Witten, I. H. et E. Frank (2005). *Data Mining : Practical Machine Learning Tools and Techniques, Second Edition (Morgan Kaufmann Series in Data Management Systems)*. San Francisco, CA, USA : Morgan Kaufmann Publishers Inc.

Summary

To develop a fault detection device represents today one of the major challenges for manufacturers of robotic systems. The detection process requires the use of a number of sensors to monitor the operation of these systems. However, the cost and constraints in the implementation of these sensors often lead designers to optimize their numbers, leading to a lack of necessary measures for the detection of failures. One way to bridge this gap is to estimate non-measurable parameters from a mathematical model describing the dynamics of the real system. This paper presents an approach based on mixed data (measured data and estimated data) for the detection of failures in robotic systems. This detection is performed using a decision tree classifier type. The data used to learning from actions taken on the real system. This data is then enriched with data estimated from one observer based on an analytical model. This enrichment as attributes further aims to increase knowledge on the functioning of the classifier system and therefore improve the rate of good detection failures. An experiment on a system for actuating a robotic seat, showing the interest of our approach, will be presented at the end of the article.