
Diagnostic et pronostic de défaillances par réseaux bayésiens

Kamal Medjaher* — **Amine Mechraoui**** — **Nouredine Zerhouni***

* *Institut FEMTO-ST, UMR CNRS 6174 - UFC / ENSMM / UTBM
Département Automatique et Systèmes Micro-Mécatronique (AS2M)
24, rue Alain Savary, 25000 Besançon, France
kamal.medjaher@ens2m.fr*

** *GIPSA-lab, CNRS UMR 5216, ENSIEG, Domaine Universitaire
BP46, 38402 Saint Martin d'Hères cedex, France
amine.mechraoui@gipsa-lab.inpg.fr*

RÉSUMÉ. Cet article a pour but de montrer l'utilisation des réseaux bayésiens statiques et dynamiques dans le domaine de la localisation des défaillances (diagnostic) et de l'anticipation ou de la prédiction des éventuelles dégradations pouvant affecter un système dynamique. Dans le premier cas, les réseaux bayésiens statiques sont utilisés pour calculer les probabilités a posteriori de ou des causes les plus probables d'une anomalie observée (observation ou évidence). Dans le second cas, les réseaux bayésiens dynamiques sont utilisés pour tenir compte de la dynamique du système et permettre de prédire son comportement futur en fonction de son état actuel et d'autres variables ou contraintes exogènes.

ABSTRACT. This paper deals with fault diagnosis and prognosis in dynamic systems by using static and dynamic bayesian networks. In the first case, static bayesian networks are used to compute the a posteriori probabilities of the most probable causes of an observed abnormal situation on the system (called evidence or observation). In the second case, dynamic bayesian networks are used in order to take into account the system's dynamic and to predict its future behaviour according to its actual state and other exogeneous variables or constraints.

MOTS-CLÉS : Défaillance, Dégradation, Diagnostic, Localisation, Pronostic, Réseaux Bayésiens, Système dynamique

KEYWORDS: Fault, Degradation, Diagnosis, Isolation, Prognosis, Bayesian networks, Dynamic systems

1. Introduction

La complexité de plus en plus croissante des systèmes industriels, ajoutée aux contraintes liées à la compétitivité et à la législation en vigueur en terme de respect de l'environnement, ont poussé les industriels et la communauté scientifique à chercher des solutions pouvant rendre ces systèmes plus performants, plus compétitifs et plus sûrs. L'un des points sur lesquels les travaux de recherche sont orientés est la maintenance conditionnelle dans laquelle sont menés des travaux sur le diagnostic et le pronostic de défaillances.

Le diagnostic de défaillances des systèmes industriels a pour rôle de détecter et de localiser les défaillances qui surviennent sur le système et aussi d'identifier les causes de ces défaillances. Effectuer un diagnostic de défaillances sur un système donné c'est identifier le mode de fonctionnement dans lequel il se trouve. Les premières méthodes de diagnostic furent basées sur la redondance de matériels jugés critiques pour le fonctionnement du système. La redondance matérielle est très répandue dans les domaines où la sûreté de fonctionnement est cruciale pour la sécurité des personnes et de l'environnement, comme dans l'aéronautique ou le nucléaire. Les principaux inconvénients de la redondance matérielle sont liés aux coûts dus à la multiplication des éléments ainsi que l'encombrement et aux poids supplémentaires qu'elle génère. Le développement des calculateurs numériques permet aujourd'hui la mise en œuvre, dans le milieu industriel, des méthodes modernes de l'automatique et de l'intelligence artificielle. Cette nouvelle approche permet d'éliminer en partie, voire même en totalité, la redondance matérielle pour le diagnostic des systèmes industriels. Globalement, on distingue deux approches de diagnostic (Isermann, 2005), (Isermann, 1997), (Toscano, 2005) : l'approche quantitative utilisant principalement des modèles analytiques (espace de parité, observateurs, estimation des paramètres, etc.), et l'approche qualitative faisant appel à des méthodes sans modèles analytiques (basées essentiellement sur les techniques de l'intelligence artificielle) (Piechowiak, 2003). Dans la première approche, quantitative, il est indispensable d'avoir un modèle mathématique des phénomènes physiques qui s'y déroulent pour réaliser un diagnostic. La qualité des résultats obtenus dépend alors fortement de la qualité du modèle obtenu. Cependant, il est très difficile, voire même impossible dans certains cas, d'obtenir un modèle qui traduise fidèlement le comportement du système. La seconde approche, qualitative, est quant à elle exploite les données disponibles pour faire de l'apprentissage ou encore, l'expertise qu'on a du système pour construire des règles. Mais, dans le cas où la base de données est incomplète ou insignifiante, ou encore si plusieurs cas sont possibles (explosion combinatoire), ces méthodes deviennent difficilement applicables et peuvent conduire à des conclusions erronées. Dans le cas des systèmes complexes où des connaissances expertes sont disponibles, il est possible d'utiliser un outil graphique bien adapté : les réseaux bayésiens (Pearl, 1988), (Naïm *et al.*, 2004). Ces derniers permettent de représenter graphiquement cette connaissance en tenant compte des incertitudes. Dans la première partie de cet article nous verrons comment les réseaux bayésiens statiques sont utilisés pour faire du diagnostic (de la localisation principalement) sur un moteur électrique à aimant permanent. Il s'agit principalement d'exploiter la structure graphique du modèle obtenu et d'utiliser les algorithmes d'in-

férence existants pour calculer des probabilité *a posteriori* de l'état des composants du système suite à une ou plusieurs observations (appelées évidences).

Contrairement au diagnostic, le pronostic de défaillances est un domaine de recherche relativement récent auquel la communauté scientifique commence à accorder une importance croissante. Plusieurs définitions du pronostic sont proposées dans la littérature. Ainsi, la norme ISO 13381-1 : 2004 (ISO, 13381-1, 2004) définit le pronostic comme étant l'estimation de la durée de fonctionnement avant défaillance et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance. Le rôle du processus de pronostic est alors d'estimer la probabilité qu'une défaillance survienne à un instant donné, ou encore de prédire le temps résiduel avant défaillance (communément appelé RUL pour Remaining Useful Life). Cela permet donc l'aide à la prise de décision et à la planification d'actions de maintenance pour éviter l'immobilisation du système et augmenter sa disponibilité et sa fiabilité. Les méthodes de pronostic peuvent être classées selon trois approches (Byington *et al.*, 2002) : le pronostic basé sur un modèle physique, le pronostic guidé par les données et le pronostic basé sur les données de retour d'expérience. Les méthodes à base de modèle physique de dégradation donnent des résultats précis (à condition de disposer d'un modèle précis) mais, en terme d'applicabilité, ces méthodes sont les moins répandues. En effet, obtenir le modèle de dégradation demande des moyens et coûte donc cher. De plus, le modèle obtenu est propre à un type de composant, matériau ou machine donné ; et ne peut donc pas être généralisé. Les méthodes utilisant des données capteurs ou opérateurs se situent au milieu de la pyramide (voir (Byington *et al.*, 2002)) en termes de précision, de coût et d'applicabilité. Dans la deuxième partie de cet article, nous proposons une procédure pour construire un modèle de pronostic pour des systèmes dynamiques en utilisant deux outils : les bond graphs (BG) (Karnopp *et al.*, 1990) et les Réseaux Bayésiens Dynamiques (RBD) (Murphy, 2002). Les premiers sont utilisés pour représenter la dynamique du système et pour extraire le modèle analytique correspondant (fonction de transfert, représentation d'état), et les seconds permettent une représentation plus générale des connaissances qu'on a du système en intégrant des variables exogènes (actions de maintenance, avis d'experts, etc.). Le présent article est organisé comme suit : la section 2 est dédiée à l'utilisation des réseaux bayésiens statiques en diagnostic de défaillances, plus particulièrement une application sur la localisation de défaillances sur un moteur électrique à aimants permanents. Ensuite, à la section 3, nous présenterons une procédure pour construire un modèle de pronostic à partir d'une description physique d'un système donné. Cette procédure sera illustrée sur un exemple de système consistant en la suspension d'un quart de véhicule. Enfin, nous terminerons par une conclusion.

2. Diagnostic de défaillances par réseaux bayésiens statiques

Le but de cette section n'est pas de présenter toute la théorie de diagnostic par réseaux bayésiens statiques, mais plutôt de donner une application de ces derniers dans la localisation de défaillances pouvant survenir sur un moteur électrique synchrone à

aimants permanents. Les lecteurs intéressés par l'aspect théorique peuvent consulter (Sheppard *et al.*, 2005) ou encore (Mecharaoui *et al.*, 2008).

2.1. Description du système

Un moteur synchrone à aimants permanents (voir figure 1) est composé principalement d'un rotor et d'un stator qui génère le mouvement de rotation transmis par l'arbre à la charge. Le stator est alimenté par un signal triphasé qui crée un champs rotatif. Grâce aux aimants permanents, le rotor tourne à la même vitesse que celle du champs rotatif créée par le stator.




Figure 1. Moteur synchrone à aimants permanents

L'objectif principal de cette application est de réaliser un diagnostic de défaillances sur le mouvement de rotation de l'arbre du moteur (on s'intéressera à la disponibilité ou non du mouvement de rotation).

2.2. Modélisation

Pour construire le réseau bayésien statique, qui sera utilisé dans l'étape de diagnostic, nous avons exploité une base de données fournie par un expert du système, qui inclue une décomposition fonctionnelle du moteur électrique dans son ensemble. A partir de cette base de données, nous avons extrait les relations causales qui existent entre les différents nœuds (représentant les composants) du graphe (étape qualitative de construction du modèle final) et ensuite, nous avons estimé les probabilités conditionnelles relatives à chacun des nœuds du graphe (étape quantitative).

La décomposition fonctionnelle existante du moteur a été utilisée dans ce qui suit pour identifier les différents nœuds du modèle graphique correspondant ainsi que les relations causales qui existent entre eux. Après cette étape qualitative, nous avons procédé à la construction du réseau bayésien utilisé en diagnostic des éventuelles défaillances pouvant affecter les composants impliqués dans le mouvement de rotation de l'arbre (voir figure 2).

Une fois la structure graphique du réseau bayésien obtenue, nous l'avons quantifié en estimant les probabilités marginales *a priori* et les probabilités conditionnelles de




Figure 2. Réseau bayésien statique du système

chacun des nœuds. Cette quantification est rendue possible grâce aux connaissances de l'expert du moteur. Pour chacun des modes des nœuds, les appréciations de l'expert sont transposées en valeurs numériques suivant une échelle de probabilité (Naïm *et al.*, 2004). Ces valeurs peuvent ensuite être modifiées en fonction de nouvelles observations ou des résultats de simulation. Les calculs sur le réseau bayésien de la figure 2 sont manuellement fastidieux à faire. Pour contourner cette difficulté, nous avons fait appel à l'utilisation du logiciel BayesiaLab pour calculer les probabilités jointes, marginales et conditionnelles. BayesiaLab est un logiciel adapté pour la modélisation, l'apprentissage et l'analyse des réseaux bayésiens. Cependant, il existe d'autres logiciels ou boîtes à outils qui traitent des réseaux bayésiens (BNT : Bayesian Networks Toolbox, Hugin, NETICA, etc.) et qui peuvent être utilisés avec succès.

2.3. Localisation de défaillances

Des simulations effectuées sur le modèle graphique final obtenu ont permis de localiser les défaillances pouvant survenir sur le système. Il s'agit de calculer les probabilité conditionnelles *a posteriori* pour chaque mode de chaque nœud du réseau. Dans ce qui suit, deux scénarios sont considérés : le mode de fonctionnement nominal et la présence d'une défaillance.

2.3.1. Mode de fonctionnement nominal :

Ce scénario correspond au mode de fonctionnement nominal du moteur (le mouvement de rotation est supposé disponible). Le réseau bayésien relatif à ce mode est donné à la figure 3.

Dans ce mode, étant donné qu'aucune anomalie n'est observée, la probabilité jointe du système complet est égale à 1. Des probabilités marginales sont calculées

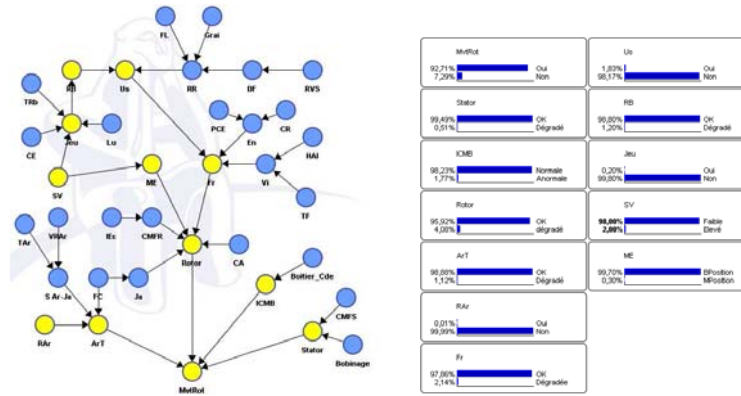


Figure 3. Scénario 1 : mode de fonctionnement nominal

pour différents nœuds. Les résultats obtenus (figure 3) montrent que la probabilité concernant la disponibilité du mouvement de rotation est de 92.71% et que celles du stator, du rotor et de l'arbre de transmission (mode OK) sont égales à 99.49%, 95.92% and 98.88% ; respectivement.

2.3.2. Localisation d'une défaillance :

Nous considérons dans ce scénario que le mouvement de rotation de l'arbre de rotation n'est pas disponible ($P(MvtRot = Non) = 1$). De plus, nous supposons qu'il existe un capteur qui permet de mesurer le spectre vibratoire (nœud SV sur le réseau de la figure 2). Dans le cas où de fortes vibrations sont détectées (observation ou évidence), la probabilité du nœud SV change et devient donc une certitude $P(SV = Elevé) = 1$. L'actualisation du réseau bayésien conduit à de nouveaux résultats de simulation donnés à la figure 4. Ces résultats montrent dans ce cas que le rotor serait la cause la plus probable du dysfonctionnement. En effet, de fortes vibrations peuvent causer d'une part, des dégradations au niveau des roulements et d'autre part, un mal positionnement des masses d'équilibre qui, à leur tour, causent la dégradation du rotor. Cela justifie donc la probabilité que le rotor soit la cause la plus probable de l'indisponibilité du mouvement de rotation ($P(rotor = dégradé | MvtRot = Non, SV = Elevé) \approx 0.87$).

3. Pronostic de défaillances par RBDs

3.1. Introduction

Contrairement au diagnostic dont le rôle est de détecter et localiser des défaillances (après apparition), le pronostic a pour but de fournir une estimation sur la durée de vie résiduelle d'un système, composant ou machine. Il permet donc d'anticiper

ensemble d'équations différentielles, on est capable de donner une estimation du RUL. Cela suppose bien évidemment l'existence de méthodes de résolution de ces équations mais aussi la définition de seuils d'alarmes au delà desquels le système est supposé entrer dans un état de défaillance. L'avantage de ces méthodes réside dans la précision des résultats qu'elles fournissent. En effet, si on dispose d'un modèle mathématique de dégradation concernant un composant donné, il est plus facile d'estimer le RUL avec une certaine confiance. Leur inconvénient majeur est qu'il est d'une part, difficile et coûteux d'obtenir le modèle et d'autre part, chaque modèle est propre à une famille de composant ou de matériau (à noter que les modèles de dégradation développés jusqu'à présent s'appuient globalement sur des phénomènes de fatigue, d'usure ou encore de corrosion).

Les méthodes à base de données reposent principalement sur l'exploitation des données fournies soit par les capteurs installés sur le système, soit par les différents opérateurs travaillant sur l'installation (observations, tests périodiques, vérifications, etc.). Ces méthodes sont basées sur l'exploitation de symptômes ou d'indicateurs de dégradations (valeur d'une grandeur physique comme la température par exemple, ou encore combinaison de plusieurs grandeurs physiques). L'évolution future de ces symptômes, réalisée par des techniques utilisant les outils de l'intelligence artificielle, des méthodes statistiques ou encore des estimateurs d'état, permet de calculer le temps restant avant l'apparition d'une défaillance (en admettant que les seuils des différents modes de fonctionnement du système sont préalablement définis). Les méthodes de cette approche de pronostic ont l'avantage de ne plus souffrir du manque de modèle analytique de la dégradation et sont donc plus simple à mettre en oeuvre que les méthodes à base de modèle physique de dégradation. Cependant, en terme de précision elles donnent des résultats moins précis que ceux la première approche.

La troisième et dernière approche de pronostic est celle utilisant les données de retour d'expérience. Le principe de cette approche repose sur l'exploitation d'une fonction de fiabilité ou d'un processus stochastique de détérioration dont les paramètres sont déterminés à partir d'expertise ou de données de retour d'expérience. Ces méthodes sont faciles à mettre en oeuvre si l'on dispose d'un volume de données de retour d'expérience suffisant et fiable pour chaque type de machine, système ou composant. En effet, une fois les paramètres de la loi de fiabilité obtenus, on peut à tout instant calculer le taux de défaillance par exemple, et donc, en fonction des conditions limites fixées, déterminer le RUL. Cependant, ces méthodes sont les moins précises et souffrent du manque de données de retour d'expérience (données incomplètes ou quasiment inexistantes, durée longue pour les obtenir, etc.). De plus, les lois de fiabilité obtenues sont propres à chaque type ou famille de composant ou machine et ne peuvent pas donc être généralisée.

Le choix des réseaux bayésiens dynamiques pour la construction d'un modèle de pronostic est justifié par la possibilité de représenter sur un même graphe la dynamique du système et des informations exogènes (avis d'experts, actions engagées, état actuel du système, etc.).

3.2. Procédure de pronostic de défaillances

Dans cette section nous présentons une procédure pour construire un modèle de pronostic de défaillances en partant d'un modèle physique d'un système dynamique. Cette procédure s'appuie sur deux outils de modélisation que sont : les bond graphs et les réseaux bayésiens dynamiques. Le couplage de ces deux outils est justifié par le fait que lorsqu'on est confronté aux systèmes dynamiques, on a besoin dans un premier temps de générer le modèle dynamique sous forme analytique (BGs), et ensuite pour les besoins du pronostic de défaillances utiliser les RBDs pour représenter, en plus de la dynamique du système, d'autres variables ou contraintes telle que la prise en compte de l'état actuel (modes de fonctionnements) ou encore les éventuelles actions de maintenance réalisées sur le système. La procédure de pronostic proposée dans cet article est réalisée en cinq étapes :

- générer le modèle BG en causalité intégrale,
- générer les résidus à partir du modèle BG en causalité dérivée,
- construire le Graphe Causal Temporelle (GCT) en utilisant le modèle BG en causalité intégrale,
- générer le RBD en exploitant la structure graphique du GCT et les informations des résidus,
- simuler le RBD obtenu pour estimer le comportement futur du système et pour fournir des métriques de pronostic.

Le modèle BG est obtenu à partir de la représentation physique du système dynamique, en représentant les transferts de puissance entre les différents éléments physiques le constituant (Karnopp *et al.*, 1990). Le modèle mathématique correspondant au comportement dynamique du système peut alors être déduit du modèle BG en causalité intégrale sous forme de fonction de transfert ou d'une représentation d'état.

Les résidus sont générés à partir du modèle BG en causalité dérivée. Cette forme de causalité est préférée dans ce cas pour deux principales raisons. D'abord, à l'instant de détection d'une défaillance, les conditions initiales ne sont pas toujours connues ; ce qui rend les calculs impossibles. Ensuite, dans la phase de localisation, on a une observation des effets (la ou les défaillances) et on essaie d'identifier les causes de ces anomalies. Ainsi, les relations de causalité sont tout simplement inversées.

Le GCT est obtenu à partir du modèle BG en causalité intégrale (Mosterman *et al.*, 1997). Ce graphe est une représentation qui capture les relations dynamiques locales entre les variables, et qui fournit une représentation plus explicite des relations entre les paramètres et les variables de comportement du système (Lerner *et al.*, 2000). Dans cette contribution, le GCT est utilisé pour construire le RBD.

Un RBD est une extension des réseaux bayésiens statiques. Ils permettent de modéliser des distributions de probabilité sur des ensembles semi-infinis de variables aléatoires (U_t, X_t, Y_t) représentant les variables d'entrée, les états cachés et les sorties d'un modèle d'état (Murphy, 2002). Les RBDs généralisent les filtres de Kalman et les chaînes de Markov (cachées et hiérarchiques). Leur utilisation permet de faire de la surveillance et de la prédiction de l'état futur du système dynamique. Dans notre

cas, le RBD du système est généré à partir du GCT en appliquant la méthode proposée initialement par (Lerner *et al.*, 2000).

A l'étape de simulation, le RBD est paramétré en spécifiant les distributions de probabilité des différents nœuds qui le composent. Ensuite, l'utilisation d'algorithmes d'inférence déjà existants (Murphy, 2002) permettra de simuler le comportement et l'état futur du système, et l'analyse des résultats obtenus peut conduire à des métriques pour le pronostic (estimation du RUL, confiance sur la valeur du RUL, etc.).

3.3. Application

Pour illustrer les étapes de la procédure proposée, on prend comme application un système physique, qui consiste en la suspension d'un quart de véhicule, et représenté à la figure 5(a). Ce système est extrait d'un cours de G. Dauphin Tanguy (Dauphin-Tanguy, 2001). Le schéma physique montre les différents phénomènes pris en compte : le profil de la route, la roue représentée par la masse m et le ressort de raideur k , le châssis représenté par la masse M , le ressort de raideur K et les frottements représentés par l'élément R de paramètre b . Le modèle BG en causalité intégrale de ce système est donné à la figure 5(b). Une analyse structurale (ordre du système, commandabilité, observabilité, etc.) peut être réalisée directement sur le modèle BG obtenu sans utiliser de modèle mathématique. Sur le modèle de la figure 5(b) on peut distinguer des éléments qui stockent de l'énergie (éléments C et I) auxquels sont associés des variables d'état, des éléments qui dissipent de l'énergie (R), et des éléments qui sont des sources d'énergie (Se et Sf). Le modèle BG en causalité intégrale permet de générer le modèle d'état du système et donc les matrices de transition, de commande et d'observation qui peuvent être utilisées lors de la construction du RBD.

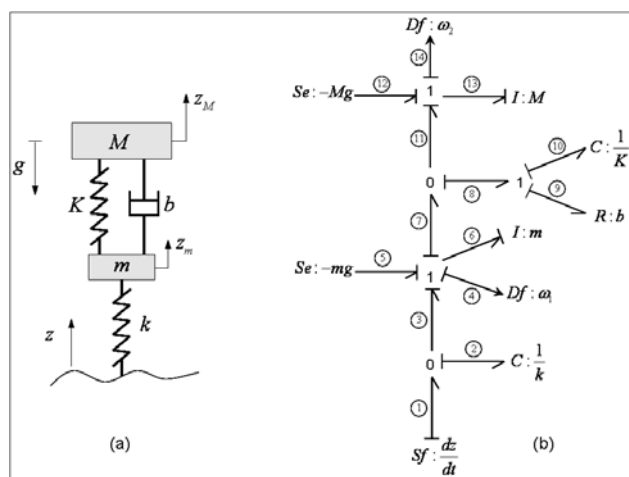


Figure 5. Système physique : (a) quart de véhicule, (b) modèle BG

Le modèle BG précédemment construit est ensuite utilisé pour générer des indicateurs de défaillances (Relations de Redondance Analytique RRA, et résidus). Brièvement, une RRA est une contrainte reliant des variables connues (mesures, entrées, paramètres) ou estimées du système, tandis qu'un résidu est une évaluation numérique d'une RRA (pour plus de détails, voir (B. Ould Bouamama *et al.*, 2006)). Les RRAs sont obtenues à partir du modèle BG en causalité dérivée préférentielle en suivant les étapes suivantes :

- mettre le modèle BG en causalité dérivée préférentielle,
- écrire les équations aux jonctions du modèle obtenu,
- éliminer les variables inconnues de chaque équation,
- générer les RRAs, et en les évaluant, déduire les résidus correspondants.

L'élimination des variables inconnues est réalisée sur le modèle BG en causalité dérivée en parcourant les chemins causaux des mesures aux variables inconnues. Pour l'exemple considéré, deux résidus peuvent être générés (le système étant totalement observable et ne comportant pas de boucles causales ni algébro-différentielles). Ces résidus sont donnés par les équations suivantes :

$$r_1 = k \left(\frac{dz}{dt} - \omega_1 \right) + m \frac{d^2\omega_1}{dt^2} - M \frac{d^2\omega_2}{dt^2} \quad [1]$$

$$r_2 = K (\omega_1 - \omega_2) + M \frac{d^2\omega_2}{dt^2} + b \frac{d(\omega_1 - \omega_2)}{dt} \quad [2]$$


A partir des résidus obtenus, la matrice de signature des défaillances du système quart de véhicule est construite directement en analysant la structure de chacun des résidus. Cette matrice est binaire, dont les lignes correspondent aux éventuelles défaillances des composants et des capteurs du système, et les colonnes les résidus. Une valeur « 1 » dans la matrice signifie qu'un résidu r_i est sensible à la défaillance du composant correspondant (représenté par un ou plusieurs paramètres dans l'équation du résidu). Deux colonnes D_b pour la détectabilité et I_b pour la localisabilité (ou isolabilité) sont ajoutées à cette matrice (voir tableau 1). Une valeur « 1 » dans D_b/I_b signifie qu'une défaillance du composant physique correspondant est détectable/isolable. Dans cet exemple, les défaillances sont toutes détectables mais seules celles affectant la roue et l'amortisseur sont localisables.

Le GCT du système de suspension du quart de véhicule est donné à la figure 6. Ce graphe est obtenu à partir du modèle bond graph en causalité intégrale préférentielle de la figure 5(b) et sur lequel on a fait apparaître les variables généralisées effort (e_i) et flux (f_i). Deux types de relations sont représentés sur le GCT, à savoir : les relations algébriques (éléments résistance) et les relations différentielles (éléments C et I). Ces relations sont utilisées lors de la construction du RBD.

Le RBD du système est montré à la figure 7. Il est construit à partir du GCT en appliquant la méthode proposée dans (Lerner *et al.*, 2000) (en traduisant les diffé-

Tableau 1. Matrice de signature des défaillances

	r_1	r_2	D_b	I_b
Roue	1	0	1	1
Amortisseur	0	1	1	1
Châssis	1	1	1	0
Capteur ω_1	1	1	1	0
Capteur ω_2	1	1	1	0

**Figure 6.** Graphe causal temporel du système

rentes relations algébriques et différentielles qui peuvent être obtenues directement du modèle BG en causalité intégrale). Sur le RBD de la figure 7 on distingue trois types de nœuds : les nœuds observés (en gris), les nœuds d'état et les nœuds représentant les éventuelles défaillances. Les paramètres du RBD sont ceux du GCT ou encore du modèle BG. Dans cette application, nous avons considéré deux défaillances : une variation anormale (hausse ou baisse) de la pression au niveau du pneu, et une détérioration de l'amortisseur (déviations de la valeur de la raideur K du ressort). Ces défaillances sont représentées sur le RBD par les nœuds (D_k, k) , (D_K, K) .

Discussion : l'application de la procédure décrite à la section 3.2 a permis d'aboutir au RBD du système de suspension du quart de véhicule. Les paramètres de ce modèle sont ceux du système physique auxquels on peut ajouter des bruits pour tenir compte des erreurs de modélisation et des bruits de mesure. De plus, nous avons ajouté des nœuds dont l'état est fonction des valeurs prises par les résidus et donc pouvant renseigner sur l'état actuel du système (mode de fonctionnement nominal, dégradé, défaillant, etc.). La simulation de ce modèle final permet alors d'obtenir des valeurs sur le RUL et l'état futur du système.




Figure 7. Réseau bayésien dynamique du système

4. Conclusion

Le diagnostic peut se révéler intéressant pour des systèmes où l'occurrence d'une défaillance est sans conséquences graves sur la sécurité des personnes ou encore sur l'environnement. Il a pour rôle de détecter, de localiser et d'identifier les défaillances afin de prendre des actions adéquates pour la conduite du système (accommodation, reconfiguration, arrêt d'urgence, etc.). Cependant, pour les processus à risque ou tout simplement pour des soucis d'économie et de disponibilité, il serait plus intéressant d'anticiper la défaillance. Ceci est réalisé par le processus de pronostic qui permet, entre autres, d'estimer la durée résiduelle avant défaillance pour mieux planifier les actions de maintenance, augmenter la disponibilité et améliorer la fiabilité du système. Dans la première partie de cet article, les réseaux bayésiens statiques ont été utilisés pour localiser des défaillances sur un moteur à aimants permanents. L'utilisation de cet outil a permis de modéliser la connaissance fournie par un expert pour faire du diagnostic. Dans la seconde partie de l'article, une procédure pour construire un modèle de pronostic pour des systèmes dynamiques relativement simples a été proposée. Cette procédure repose sur le couplage de deux outils : les BGs et les RBDs. Les premiers sont utilisés pour modéliser les phénomènes physiques propres au système, et les seconds pour intégrer au modèle de comportement dynamique généré des connaissances exogènes telle que la prise en compte d'informations issues des résidus ou encore les bruits de modélisation et de mesure. La simulation du modèle graphique final construit peut être exploitée pour fournir des indicateurs. Ces derniers peuvent être utilisés pour qualifier les performances futures du système et pour aider à la prise de décision concernant les éventuelles actions à entreprendre afin d'augmenter sa disponibilité et améliorer sa fiabilité.

5. Bibliographie

- Byington C., Roemer M., Kacprzyński G., Galie T., « Prognostic Enhancements to diagnostic Systems for Improved Condition-based maintenance », *2002 IEEE Aerospace Conf., Big Sky, USA*, 2002.
- Dauphin-Tanguy G., « Cours de DEA : la méthodologie bond graph pour la modélisation des systèmes dynamiques », Ecole Centrale de Lille, 2001.
- Isermann R., « Supervision : fault-detection and fault-diagnosis methods. An introduction », *Control Engineering Practice*, vol. 5, p. 639-652, 1997.
- Isermann R., « Model-based fault-detection and diagnosis - status and applications », *Annual Reviews in Control*, vol. 29, p. 71-85, 2005.
- Karnopp D., Margolis D., Rosenberg R., *Systems Dynamics : A Unified Approach*, 2nd edn, John Wiley, New York, 1990.
- Lerner U., Parr R., Koller D., Biswas G., « Bayesian Fault Detection and Diagnosis in Dynamic Systems », *Proc. of American Association for Artificial Intelligence*, 2000.
- Mecharaoui A., Medjaher K., Zerhouni N., « Bayesian based fault diagnosis : application to an electrical motor », IFAC World Congress, 2008. A paraître.
- Mosterman P., Biswas G., « Monitoring, prediction and fault isolation in dynamic physical systems », *Proc. of AAAI*, p. 100-105, 1997.
- Muller A., Contribution à la maintenance prévisionnelle des systèmes de production par la formalisation d'un processus de pronostic, PhD thesis, Université Henri Poincaré, Nancy 1, 2005.
- Murphy P., Dynamic Bayesian Networks : Representation, Inference and Learning, PhD thesis, Univ. of California, Berkeley, 2002.
- Naïm P., Wuillemin P., Leray P., Pourret O., Becker A., *Réseaux bayésiens*, Eyrolles, 2004.
- Pearl J., *Probabilistic reasoning in intelligent systems : Networks of plausible inference*, Morgan Kaufman Publishers, 1988.
- Piechowiak S., « Intelligence artificielle et diagnostic », *Techniques de l'ingénieur*, 2003.
- Provan G., « Prognosis and condition-based monitoring : an open systems architecture », *5th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, p. 57-62, 2003.
- Sheppard J. W., Kaufman M. A., « A Bayesian Approach to Diagnosis and Prognosis Using Built-In Test », *IEEE Transactions on Instrumentation and Measurement*, vol. 54, n° 3, p. 1003-1018, 2005.
- B. Ould Bouamama, Medjaher K., Samantaray A., Staroswiecki M., « Supervision of an industrial steam generator. Part I : Bond graph modelling », *Control Engineering Practice*, vol. 14, n° 1, p. 71-83, 2006.
- ISO, 13381-1, *Condition monitoring and diagnostics of machines - prognostics - Part1 : General guidelines*, Int. Standard, ISO, 2004.
- Toscano R., *Commande et diagnostic des systèmes dynamiques*, Ellipses, 2005.
- Vachtsevanos G., F.L. Lewis, Roemer M., Hess A., Wu B., *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*, New Jersey, Hoboken : Wiley & Sons, 2006.