

Les Réseaux Bayésiens versus d'autres modèles probabilistes pour le diagnostic multiple de systèmes complexes.

Véronique Delcroix*, Mohamed-Amine Maalej*
Sylvain Piechowiak*

*LAMIH, Université de Valenciennes et du Hainaut-Cambrésis, Le Mont Houy, 59
313 Valenciennes cedex 9

Veronique.Delcroix,Mohamed-Amine.Maalej,Sylvain.Piechowiak@univ-valenciennes.fr
[http ://www.univ-valenciennes.fr/LAMIH/](http://www.univ-valenciennes.fr/LAMIH/)

Résumé. Le diagnostic multiple à base de réseaux bayésiens hérite, entre autre, des travaux sur le diagnostic à base de modèles dont certains exploitent les probabilités. D'autre part, de nombreuses applications des réseaux bayésiens portent sur le diagnostic de systèmes peu ou moyennement complexes ou encore sur le diagnostic médical. Cet article présente en détail l'intérêt du modèle graphique probabiliste que nous utilisons pour le diagnostic de gros systèmes et le compare à d'autres modèles probabilistes utilisés, avec ou sans les réseaux bayésiens.

1 Introduction

Notre travail se situe dans le contexte du diagnostic de systèmes fiables et de grande taille. Les systèmes que nous considérons sont constitués de composants, reliés entre eux par leurs entrées ou sorties. Un composant C est soit en bon état $ok(C)$ soit défaillant $ab(C)$. Nous supposons que certaines observations sur le système ont révélé une défaillance du système. En d'autres termes, l'ensemble des valeurs observées sur certaines variables d'entrée/sortie de composants n'est pas compatible avec le fait que tous les composants du système soient en bon état. L'objectif du diagnostic est de trouver le composant défaillant ou l'ensemble de composants défaillants qui explique le mieux les observations de panne. Plusieurs aspects rendent cette tâche difficile : la grande taille des systèmes considérés implique qu'un grand nombre de composants sont susceptibles d'être défaillants ; de plus, comme les systèmes considérés sont fiables, peu de scénarios de pannes sont connus et ils ne peuvent pas être utilisés pour la recherche des diagnostics. En revanche, la fiabilité au niveau de chaque composant est connue et peut être exprimée sous la forme d'une probabilité de défaillance au niveau de chaque composant.

Dans ce contexte, les réseaux bayésiens sont bien adaptés comme modèle pour le diagnostic de tels systèmes. D'une part ils permettent de construire un modèle de bon et de mauvais fonctionnement du système ; ce qui permet de chercher les diagnostics sans disposer d'un historique des pannes. D'autre part, les réseaux bayésiens permettent de prendre en compte les probabilités de défaillance *a priori* des composants. Ils permettent aussi de calculer facilement les probabilités de défaillance *a posteriori* des composants, c'est à dire sachant les observations.

On trouve dans la littérature de nombreuses structures de réseaux bayésiens (graphe) utilisées pour le diagnostic. Nous les comparons dans cet article avec la structure que nous utilisons et expliquons pourquoi les autres structures ne sont pas adaptées au diagnostic de systèmes fiables et de grande taille. Nous comparons aussi avec d'autres modèles probabilistes utilisés pour le diagnostic.

Après avoir donné la définition des termes utilisés, nous décrivons le type de réseaux bayésiens que nous utilisons pour la recherche des diagnostics et présentons notre algorithme de diagnostic à base de réseau bayésien. Dans la partie suivante, nous comparons successivement notre approche à d'autres qui utilisent le même modèle, ou qui proposent d'autres types de réseaux bayésiens pour le diagnostic, ou enfin qui n'exploitent pas les réseaux bayésiens mais exploitent les probabilités.

2 Définitions et présentation du modèle utilisé

Un *réseau bayésien* est un graphe orienté sans circuit dont les nœuds représentent les variables du système. A chaque nœud est associée une distribution de probabilité conditionnelle qui définit la probabilité de chacune de ses valeurs, connaissant les valeurs des nœuds prédécesseurs directs dans le graphe. On trouvera une introduction plus complète aux réseaux bayésiens dans (Becker et Naïm, 1999). Nous appelons *variables* du système les variables associées aux entrées/sorties des composants et les variables d'état des composants. Nous supposons que les variables d'état des composants sont indépendantes.

On appelle *observations* l'ensemble des nœuds dont on connaît la valeur de façon certaine. Des *observations de pannes* ou *symptôme* (de Kleer 1991) sont des observations incompatibles avec l'état normal du dispositif, c'est à dire tel que $P(ok(\mathcal{C}), Obs) = 0$ où \mathcal{C} est l'ensemble des composants du système. Ces observations révèlent un dysfonctionnement et signifient qu'au moins un composant est dans l'état anormal. Un *état du système* représente une affectation d'un état (*ok* ou *ab*) à tous les composants du système.

Nous adoptons une définition classique du diagnostic : un *diagnostic* est un état du système cohérent avec les observations de panne. Pour simplifier les explications, nous désignerons parfois un diagnostic comme l'ensemble des composants défaillants, en sous-entendant que les autres composants fonctionnent correctement. Un diagnostic est *minimal* si aucun de ses sous-ensembles stricts n'est lui-même un diagnostic. Un diagnostic est *simple* ou *multiple* selon qu'il incrimine un ou plusieurs composants défaillants. La *taille* d'un diagnostic est le nombre de ses composants (défaillants). L'objectif est de calculer les "meilleurs" diagnostics et leur probabilité *a posteriori*, c'est à dire $P(ab(\mathcal{C}_K) \wedge ok(\mathcal{C}_{NK}) \mid Obs)$ où \mathcal{C}_K est un sous-ensemble de composants et \mathcal{C}_{NK} est son complémentaire.

L'élaboration du réseau bayésien que nous utilisons pour la recherche des diagnostics suit le procédé décrit par (Geffner et Pearl 1987) et repris dans (Srinivas 1994), (Poole 1996), (Lerner et al. 2000) et (Lerner 2002). Les nœuds du réseau bayésien représentent deux types de variables : celles associées aux états des composants et celles associées aux entrées et sorties des composants. Ces dernières peuvent être observables ou non.

La structure complète d'un réseau bayésien s'obtient par l'assemblage de réseaux




FIG. 1 – Réseau bayésien élémentaire d’un composant




FIG. 2 – Circuit d’un additionneur un bit et son réseau bayésien

bayésiens élémentaires qui modélisent chaque composant (figure 1). Ainsi, l’état d’un composant n’influe pas sur l’état des autres composants. En revanche, une valeur de sortie anormale (due à la défaillance d’un composant), influe sur les valeurs de sortie des composants en aval. Les probabilités *a priori* des nœuds états des composants représentent les probabilités de défaillance *a priori* des composants. Pour les systèmes fiables, les constructeurs fournissent une mesure de la fiabilité des composants, ce qui permet de définir ces probabilités. Pour les nœuds de sortie d’un composant, leur distribution de probabilités décrit le comportement du composant. Les probabilités “sachant que le composant est en bon état” sont en général 0 ou 1 (comportement déterministe). Si le comportement d’un composant en panne est connu, il est utilisé pour expliciter les probabilités des variables de sorties en mode défaillant. C’est le cas, en particulier, des composants sécurisés pour lesquels certaines valeurs de sortie en mode défaillant sont imposées ou interdites. Dans le cas contraire, nous supposons que les valeurs de sorties sont équiprobables.

La figure 2 représente le schéma d’un additionneur un bit et le graphe du réseau bayésien qui lui est associé. La figure 3 présente la table de probabilité conditionnelle du nœud *Ret1*, c’est à dire $P(Ret1 | Out_and1, Out_and2, State_Or)$ et la table de probabilité d’un nœud d’état d’un composant.

State_or	OK				ab			
Out_and1	on	off	on	off	on	off	on	off
Out_and2	on	off	on	off	on	off	on	off
▶ on	1	1	1	0	0.5	0.5	0.5	0.5
▶ off	0	0	0	1	0.5	0.5	0.5	0.5

▶ OK	0.99999
▶ ab	1e-005

FIG. 3 – Table de probabilité du nœud “Ret1” et d’un nœud “Etat d’un composant”

3 Notre algorithme de diagnostic

Le but de notre algorithme est de calculer et d’ordonner des diagnostics simples et multiples pour un dispositif modélisé par un réseau bayésien. Il nécessite de connaître des observations de panne. Une première version de cet algorithme a été publiée dans (Delcroix et al., 2002).

3.1 L’approximation

Le calcul de la probabilité *a posteriori* d’un diagnostic $P_{D_K} = P(ab(C_K) \wedge ok(C_{NK}) | Obs)$ est extrêmement coûteux. Pour pallier ce problème, nous proposons un calcul approché de la probabilité *a posteriori* des diagnostics à partir des probabilités de défaillance *a posteriori* de chaque composant. Notre approximation repose sur le raisonnement suivant : soient un ensemble d’observations de panne Obs et un ensemble C_K de composants tous défaillants qui explique ces observations (c’est à dire que $D_K = ab(C_K) \wedge ok(C_{NK})$ est un diagnostic pour Obs). Puisque l’état du système D_K explique les observations de pannes, et que les composants de C_K sont effectivement en panne, alors les autres états du système qui pourraient aussi expliquer ces observations de panne ne sont pas les bonnes. Il n’y a donc plus lieu de suspecter les autres composants (ceux de C_{NK}). Leur probabilité de défaillance sachant peut donc être considérée comme égale à leur probabilité de défaillance habituelle (probabilité *a priori*). Ceci revient à approcher $P(ok(C_{NK}) | ab(C_K), Obs)$ par $P(ok(C_{NK}))$. En multipliant par $P(ab(C_K) | Obs)$, on a : $P_{D_K} \approx P(ab(C_K) | Obs) \cdot P(ok(C_{NK}))$ et comme les composants sont indépendants *a priori*, on a l’approximation suivante de P_{D_K} :

$$P_{D_K} \approx P(ab(C_K) | Obs) \cdot \prod_{C_k \in C_{NK}} P(ok(C_k))$$

Dans le cas d’un diagnostic simple on a $P_{D_i} \approx P_{C_i} \cdot \prod_{k \neq i} P(ok(C_k))$. Nous exploitons cette approximation pour calculer la probabilité des diagnostics *a posteriori*.

3.2 Calcul des diagnostics les plus probables

Notre algorithme commence par déterminer et ordonner la liste des composants suspects (LCS). Le calcul et le classement sont basés sur la probabilité de défaillance *a posteriori* de chaque composant comme cela est proposé dans (Srinivas 1994). La liste des composants suspects est tronquée de façon à réaliser la recherche des diagnostics

sur un ensemble restreint de composants. Ce premier niveau ne permet pas de savoir si un composant appartient à un diagnostic simple ou multiple, ou à aucun.

L'étape suivante de l'algorithme teste donc si les composants de LCS constituent des diagnostics simples. Le cas échéant, leur probabilité *a posteriori* est calculée à l'aide de l'approximation et le composant est supprimé de LCS .

L'algorithme calcule enfin les diagnostics multiples et une estimation de leur probabilité *a posteriori*. Pour cela, seuls les composants restants dans LCS sont considérés, c'est à dire les composants suspects n'appartenant pas à des diagnostics simples. Le calcul des diagnostics multiples est récursif, jusqu'à une taille maximale fixée.

La dernière étape consiste à supprimer les diagnostics non minimaux de taille supérieure ou égale à trois obtenus dans l'étape précédente. Considérons en effet l'exemple suivant : soit $LCS = \{C_1, C_2, C_3\}$ et la taille maximale des diagnostics recherchés est fixée à 3. Lors de la recherche des diagnostics multiples, l'ensemble $\{C_1, C_2\}$ est testé, puis, s'il n'est pas un diagnostic, l'ensemble $\{C_1, C_2, C_3\}$ est testé. Si ce dernier est un diagnostic, il ne sera finalement conservé que s'il est minimal, c'est à dire si $\{C_1, C_3\}$ et $\{C_2, C_3\}$ ne sont pas des diagnostics.

4 Comparaison avec d'autres approches probabilistes pour le diagnostic

Dans cette partie, nous situons notre travail par rapport à d'autres approches probabilistes du diagnostic. Nous commençons notre comparaison avec les approches qui utilisent le même modèle que le notre, puis avec celles qui proposent d'autres types de réseaux bayésiens pour le diagnostic. Enfin nous comparons notre approche avec celles qui n'exploitent pas les réseaux bayésiens mais dont l'objectif est proche de celui qui nous intéresse : le calcul des probabilités *a posteriori* pour les meilleurs diagnostics. Pour les systèmes de grande taille qui nous intéressent, la liste des diagnostics simples ou multiples correspondant à des observations de pannes peut vite devenir très longue. Notre objectif est de ne calculer que les diagnostics les plus probables, ainsi que leur probabilité, et non la liste exhaustive des diagnostics. Sans ce calcul, des observations supplémentaires, parfois couteuses, seraient nécessaires pour trouver les meilleurs diagnostics.

4.1 Les méthodes de diagnostic qui utilisent ce modèle

Dans (Geffner et Pearl 1987) et (Srinivas 1994), qui utilisent le modèle décrit ci-dessus, c'est la probabilité de défaillance *a posteriori* au niveau de chaque composant qui constitue le diagnostic. Aucune probabilité conjointe n'est calculée. Ce calcul constitue pour nous la première étape de notre algorithme de diagnostic.

Les travaux de (Poole 1996) exploitent la même structure de réseaux bayésiens, mais en vue d'un calcul différent. L'objectif de Poole est d'estimer les probabilités *a posteriori* des "mondes" les plus probables, c'est à dire affecter une valeur à toutes les variables du système et non aux seules variables d'état des composants. Pour cela, le réseau est simulé avec ses valeurs "normales" (probabilité *a priori* proche de 1). Lorsque les valeurs prédites contredisent les observations, la simulation se poursuit avec

différentes valeurs pour les variables des conflits (Reiter 1987). Ces simulations donnent lieu à différents “univers” possibles à partir desquels sont estimées les probabilités *a posteriori* des diagnostics. La méthode proposée par Poole est bien adaptée lorsque les probabilités qui définissent le réseau sont extrêmes, c’est à dire très proches de 0 ou de 1, y compris pour les probabilités *a priori* des noeuds sans parents. Ceci n’est en général pas le cas des systèmes que nous considérons.

Enfin, cette structure de réseau bayésien est également utilisée dans (Lerner et al. 2000) et (Lerner 2002) pour le diagnostic de systèmes dynamiques. Dans ce cas, la structure est dupliquée pour les tranches de temps t et $t + 1$, avec des liens entre un noeud et son équivalent à $t + 1$. L’algorithme utilisé pour calculer la probabilité *a posteriori* d’un état du système à l’instant t sachant toutes les observations faites jusqu’à t repose sur l’énumération de toutes les instantiations possibles des variables de pannes correspondant pour nous aux variables d’état des composants. Cette hypothèse limite fortement la taille des systèmes considérés. L’exemple industriel traité contient une trentaine de pannes simples possibles.

4.2 D’autres structures de réseaux bayésiens pour le diagnostic

De nombreux articles de la littérature exploitent d’autres structure de réseaux bayésiens pour le diagnostic. Les premiers travaux que nous présentons ci-dessous visent la recherche de diagnostics simples. Les deux dernières approches abordent le diagnostic multiple mais ne cherchent pas à calculer la probabilité *a posteriori* des diagnostics.

L’étude sur la modélisation de processus industriels décrite dans (Weber 2004) utilise des diagrammes d’influence. Ce modèle associe des réseaux bayésiens orientés objets (RBOO) et des noeuds d’utilité. La structure utilisée est assez proche de celle décrite plus haut, et repose à la fois sur les analyses fonctionnelle et dysfonctionnelle du système. L’objectif de cette étude inclut un aspect simple du diagnostic : le calcul de la probabilité de défaillance *a posteriori* pour chaque composant. Il s’agit de diagnostic simple concernant des systèmes de taille petite ou moyenne. Un modèle similaire est décrit dans (Weber, 2003) pour des systèmes dynamiques, à l’aide de RBOO dynamiques.

Un exemple de diagnostic de panne de voiture est donné avec le logiciel NETICA¹ (voir figure 4). La structure utilisée est proche de celle décrite plus haut mais non systématique. Les noeuds rectangle y représentent les composants du système et leur état. Cependant aucun noeud ne représente l’état de la batterie. L’age de la batterie et sa tension sont des indicateurs mais aucun n’indique exactement si ce composant est défaillant. Les noeuds intermédiaires représentent presque tous l’état de sous-systèmes de la voiture plutôt que les variables de sortie des composants (comme la tension pour la batterie). Ce réseau bayésien permet de calculer facilement la probabilité de défaillance *a posteriori* de chaque composant, ce qui donne une bonne idée des diagnostics simples mais ne permet pas la recherche de diagnostic multiples.

Dans (Kipersztok 2002) l’auteur utilise des réseaux bayésiens pour diagnostiquer les principaux systèmes d’avions. Il définit un diagnostic comme la liste partiellement ordonnée des causes probables, triées suivant leur probabilité *a posteriori*. Il calcule

¹Netica is trademarks of Norsys Software Corp, <http://www.norsys.com/>

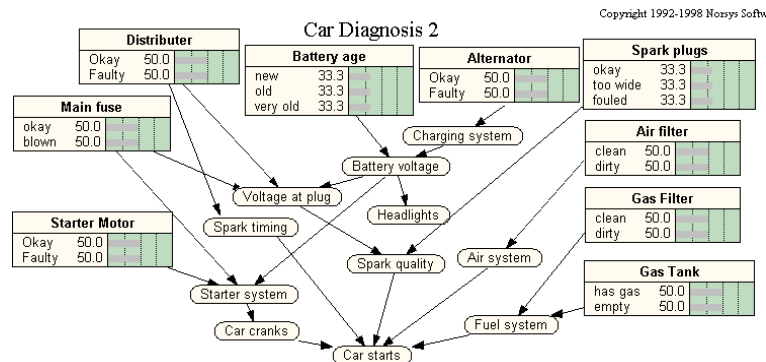


FIG. 4 – Exemple de Réseau Bayésien pour le Diagnostic de voiture

la probabilité sur un composant et non sur l'ensemble des composants. Dans ce cas, le réseau bayésien est construit en reliant les causes de pannes aux effets observés. L'auteur précise que le réseau bayésien utilisé modélise directement la façon dont le système est défaillant et non la façon dont le système s'écarte d'un comportement normal. Dans ce cas, le réseau bayésien utilisé ne modélise pas le comportement normal du système.

Les équipes de Microsoft (Breese and Heckerman 1996) et d'Aalborg au Danemark (Skaanning et al.2000) se concentrent sur le dépannage et la réparation plutôt que sur la recherche de diagnostic. Dans (Breese and Heckerman 1996), l'objectif est de générer une séquence d'actions de réparations et d'observations optimale en terme de coût. Les cas traités concernent quelques dizaines de composants. Ces auteurs posent l'hypothèse de panne simple comme approximation pour simplifier les calculs. Ils cherchent à calculer la probabilité pour que le dispositif revienne dans un état de fonctionnement correct après qu'un composant ait été réparé. Le modèle utilisé suppose l'existence d'une variable observable donnant l'état du système à diagnostiquer, par exemple "l'imprimante fonctionne", ou "la voiture démarre", (cf figure 4). Cette hypothèse est raisonnable pour de petits systèmes mais pas pour des systèmes de grande taille.

L'exemple du diagnostic médical donné par (Spiegelhalter 1993) exploite un réseau bayésien qui contient un noeud "Diagnostic". Ses valeurs sont à la fois exhaustives et exclusives : ce sont toutes les maladies possibles, sachant que le symptôme d'asphixie à la naissance a été observé. Avec un tel noeud, le réseau bayésien calcule une probabilité du type $P(Diagn|Obs)$ mais l'ensemble des diagnostics est très restreint et ne contient que des diagnostics simples. L'extension à des cas plus importants en nombre de diagnostics possibles (simples ou multiples) est impossible du fait de l'explosion de la taille du modèle. Par ailleurs, l'observation qui révèle la présence d'une maladie est distincte des observations permettant d'établir le diagnostic.

Dans (Darwiche 1995), les réseaux bayésiens utilisés ne modélisent pas l'état des composants mais seulement les variables du dispositif. Ils servent à calculer les conséquences des observations sous la forme d'une expression booléenne dont les termes sont du type

$ab(C)$. Cette expression prend l'apparence d'un arbre "et-ou" qui sert à évaluer les diagnostics "préférés" en utilisant un coût pour chaque littéral $ab(Ci)$.

La méthode utilisée dans (Ibargüengoytia et al. 2000, 2001) utilise successivement deux types de réseaux bayésiens pour détecter et localiser les pannes possibles puis pour identifier les pannes réelles. Dans le premier réseau bayésien, chaque noeud représente un capteur. Les auteurs distinguent panne réelle et panne apparente : une panne apparente est la conséquence d'une panne réelle. Cette distinction est nécessaire du fait que le modèle proposé confond en une seule variable l'état d'un capteur et la valeur mesurée. De ce fait, la méthode proposée convient au diagnostic de capteurs, mais son application au diagnostic de systèmes logiques proposée dans (Ibargüengoytia et al. 2000) s'avère mal adaptée. Dans le modèle que nous utilisons, la panne d'un composant peut provoquer une valeur anormale sur une variable de sortie du composant et être propagée aux variables de sortie des composants en aval, mais elle n'affecte pas l'état de ces composants. Par ailleurs, la méthode de diagnostic proposée dans (Ibargüengoytia et al. 2000, 2001) ne permet pas toujours d'identifier les diagnostics multiples, ni de les classer.

4.3 D'autres modèles probabilistes pour le diagnostic

Nous présentons ici d'autres travaux plus proches du notre en terme d'objectif, mais qui n'exploitent pas ou très peu les réseaux bayésiens.

La méthode proposée par (De Kleer 1991) s'inscrit dans le diagnostic à base de modèle et exploite fortement les probabilités, mais l'auteur n'utilise pas les réseaux bayésiens. De Kleer propose une stratégie de recherche des diagnostics les plus probables en premier. Les diagnostics sont générés séquentiellement par ordre décroissant des probabilités *a priori*. Puis, un ATMS (Assumption-based Truth Maintenance System) hybride est utilisé pour générer les prédictions et les conflits relatifs au diagnostic traité. Ceci permet d'évaluer la probabilité *a posteriori* des diagnostics moyennant une hypothèse simplificatrice. Pour limiter le nombre des composants suspectés, de Kleer calcule les probabilités *a priori* des diagnostics multiples en utilisant les probabilités de défaillance *a priori* des composants. L'auteur propose plusieurs choix pour limiter la recherche des diagnostics. Ces méthodes peuvent être utilisées dans notre procédure de sélection des composants suspects en utilisant la probabilité *a posteriori* de défaillance des composants et non les probabilités *a priori*. La méthode de De Kleer permet d'obtenir un nombre "raisonnable" de diagnostics possibles. Cependant, le risque subsiste d'éliminer certains diagnostics plus probables que d'autres *a posteriori*. Ce risque est écarté dans notre algorithme. De Kleer résoud rapidement le calcul de la probabilité *a posteriori* des diagnostic de la façon suivante. Il utilise la règle de Bayes, puis fait une hypothèse de probabilité uniforme pour calculer $P(Obs|D)$ lorsque cette probabilité n'est ni 1 ni 0. En réalité, cette hypothèse n'est pas toujours acceptable. En effet, si l'on connaît le comportement de certains composants lorsqu'ils sont défaillants, cela rend certaines observations plus probables que d'autres pour un même état du système. De plus, le cas où $P(Obs|D) = 1$ ne peut se produire si l'on accepte qu'un composant défaillant peut se comporter de façon non déterministe.

Les trois propositions suivantes se succèdent en s'inspirant des précédentes (Laskey et Lehner 1989), (Kohlas et al. 1998), (Lucas 2001). Dans (Laskey et Lehner 1989),

les auteurs exploitent la théorie de Dempster-Shafer dans un ATMS. Ils expliquent comment calculer les fonctions de croyance de Dempster-Shafer à partir d'un ensemble de justifications d'un ATMS et des probabilités sur les hypothèses. Etant donnée une justification de la forme : $r, A \rightarrow h$, où A est une hypothèse (correspondant, pour nous, à l'état d'un composant) et r et h sont deux propositions, la croyance $Bel(h)$ peut être interprétée comme la probabilité que les observations soient suffisantes pour prouver la proposition, c'est à dire $P(h | r)$.

Cette approche est étendue par (Kohlas et al. 1998). Les auteurs utilisent la description logique du dispositif et les probabilités de défaillance des composants pour calculer la probabilité *a posteriori* d'un diagnostic candidat. Les probabilités utilisées portent uniquement sur les propositions, et non sur les hypothèses alors que les probabilités que nous utilisons pour la définition du réseau bayésien sont du type $P(h | r, A)$. Par ailleurs, les auteurs mentionnent dans (Laskey et Lehner 1989) que si on ajoute une justification de la forme $r, \neg A \rightarrow \neg h$, alors on peut écrire que $P(A) = P(h | r)$. Il est ainsi possible d'utiliser les probabilités sur les hypothèses pour calculer des croyances. Nous n'exploitons pas cette approche dans notre étude car les probabilités nécessaires à la définition du réseau bayésien d'un composant ne peuvent être calculées à partir de celles décrites par les auteurs précédents. D'autre part, nous ne supposons pas qu'un composant défaillant "ment". Les probabilités *a posteriori* calculées par Kohlas ne correspondent pas exactement à celles que nous calculons. Dans (Kohlas et al. 1998), le calcul concerne la probabilité *a posteriori* d'un état du système sachant N_d , l'ensemble des états du système compatibles avec les observations (Obs). Nous calculons la probabilité d'un état du système sachant les observations. En pratique il est possible que différents ensembles d'observations déterminent le même ensemble de diagnostic. Dans ce cas, il se peut que certaines observations rendent plus probables certains diagnostics. En revanche la probabilité $P(D | N_d)$ calculée par (Kohlas et al. 1998) reste constante quelque soit l'ensemble d'observations puisque cette probabilité ne repose que sur les probabilités *a priori* des diagnostic de N_d . La différence entre $P(D | N_d)$ et $P(D | Obs)$ vient du fait que les modèles utilisés sont différents. Le modèle que nous utilisons prend en compte finement le comportement des composants en mode défaillant en incluant des probabilités alors que le modèle utilisé par (Kohlas et al. 1998) est plus restrictif.

(Lucas 2001) propose une méthode mixte qui s'appuie sur les travaux de (Kohlas et al. 1998) et permet de s'affranchir de l'hypothèse d'indépendance des composants. Il utilise un réseau bayésien en complément du modèle classique utilisé dans le diagnostic à base de modèle. Son réseau bayésien modélise la dépendance entre les composants lorsque certains sont défaillants. Les noeuds de ce réseau sont uniquement des noeuds d'état des composants et les variables observables. Ce réseau contient aussi de l'information sur les relations entre certaines observations et l'état des certains composants. Lucas appelle ce réseau bayésien "the bayesian observation model". Il permet de calculer les conflits ainsi que les probabilités de la forme $P(Obs | C_1 \cdots C_n)$, ce qui permet de calculer les probabilités *a posteriori* des diagnostics. L'inconvénient de cette méthode réside dans la difficulté de construire le réseau bayésien, dans le cas de gros systèmes, ou dans le cas des systèmes dont les pannes (les observations de pannes) sont mal connues. A l'inverse, la construction des réseaux bayésiens que nous utilisons découle directement de la structure du système et peut être réalisée de manière systématique.

4.4 Conclusion sur le modèle

Parmi les types de réseaux bayésiens recensés pour le diagnostic, certains ne comportent que des noeuds représentant l'état des composants, d'autres, à l'inverse, ne contiennent que les variables d'entrées/sorties des composants. Plusieurs approches consistent aussi à exploiter des informations issues de plusieurs modèles (logiques, graphiques et probabilistes). Un des intérêts essentiels du type de réseau bayésien que nous utilisons est d'une part de regrouper la totalité de l'information sur le même modèle, d'autre part de séparer clairement l'état (normal ou défaillant) d'un composant et les conséquences de cet état sur les variables de sortie. Ce modèle permet de calculer aisément les probabilités de défaillance *a posteriori* des composants, ce qui est l'intuition de plusieurs approches utilisant déjà ce même modèle. Cependant, il ne permet pas de calculer directement les probabilités *a posteriori* des diagnostics (simples ou multiples) (probabilités conjointes). C'est pourquoi nous proposons un algorithme pour calculer une approximation de ces probabilités pour les meilleurs diagnostics.

Nous remercions pour leur soutien la région Nord-Pas de Clais, et le projet ST2 sur la sécurité dans les transports.

Références

- Becker A. et Naïm P. (1999), Les réseaux bayésiens, Modèles graphiques de connaissances, Eyrolles, 1999.
- Breese J.S. and Heckerman D. (1996), Decision-Theoretic Troubleshooting : A framework for repair and experiment, in UAI, 1996, pp. 124–132.
- Darwiche A. (1995), Model-based Diagnosis using Causal Networks, Proc. of the 14th IJCAI, 1995, pp 211–217.
- De Kleer J. (1991), Focusing on probable diagnoses, Proc. 9th Nat. Conf. On AI 1991, pp 842-848.
- Delcroix V., Piechowiak S. Rodriguez J. (2002), Computing diagnoses with higher posterior probability using bayesian networks, in Esia (Eds) Proc. of Intern. Conf. on Information Processing and management of Uncertainty in Knowledge based-system, 2002, pp 45–51.
- Geffner H. et Pearl J. (1987), An improved constraint-propagation algorithm for diagnosis, Proceedings IJCAI-87, Milan,1987, pp 1105–1111.
- Ibagüengoytia P.H., Sucar L.E., Morales E. (2000), Probabilistic model-based diagnosis, Proc. of the Mexican Intern. Conf. on Artificial Intelligence, 2000, pp 687–698.
- Ibagüengoytia P.H., Sucar L.E., Vadera S. (2001), Real time intelligent sensor validation, IEEE Transactions on Power Systems, 2001, vol. 16, pp 770-775.
- Kipersztok O. (2002), Validation of diagnostic models using graphical belief networks, in 9th Intern. conf IPMU 2002, Information Processing and Management of Uncertainty in Knowledge-based Systems, pp. 39-44, 2002.
- Kohlas J., Anrig B., Haenni R. and Monney P.A. (1998) Model based diagnostics and probabilistic assumption-based reasoning, Artificial Intelligence 104 :71-106, 1998.

- Leray, P. Francois, O. (2004). Réseaux bayésiens pour la classification - méthodologie et illustration dans le cadre du diagnostic médical. *Revue d'Intelligence Artificielle*, 18 :169-193, 2004.
- Lerner U., Parr R., Koller D. and Biswas G. (2000), Bayesian Fault Detection and Diagnosis in Dynamic Systems, in *Proceedings of AAAI-2000*, pp 531–537.
- Lerner U. (2002) PhD Thesis : Hybrid Bayesian Networks for Reasoning about Complex Systems, in Stanford University, 2002.
- Poole D. (1996), Probabilistic conflicts in search algorithm for estimating posterior probabilities in Bayesian networks, *Artificial Intelligence*, 88 :69-100, 1996.
- Reiter R. (1987), A theory of diagnosis from first principle, in *Artificial Intelligence*, 32 :57–95, 1987.
- Skaanning C., Jensen F.V. and Kjaerulff U. (2000), Printer Troubleshooting using Bayesian Networks, in *IEA/AIE, 2000*, pp. 367–379.
- Spiegelhalter D.J., Dawid P., Lauritzen S.L. and Cowell R.G. (1993), Bayesian analysis in expert systems, *Statistical Science*, 8 :219–283, 1993.
- Srinivas S. (1994) A probabilistic approach to hierarchical model-based diagnosis, 10th conf. on UAI, 538-545, Seattle, 1994.
- Weber, P. and Jouffe, L. (2003). Reliability modelling with dynamic bayesian networks. In *Proceedings of 5th IFAC Symposium on Fault Detextion, Supervision and Safety of Technical Processes (SAFEPROCESS'03)*, pages ??-??, Washington, D.C., USA.
- Weber, P. and Suhner, M. (2004). Modélisation de processus industriels par réseaux bayésiens orientés objets (rboo) - application à l'analyse des performances d'un processus industriel. *Revue d'Intelligence Artificielle*, 18 :299-326, 2004.

Summary

Multiple diagnosis methods using bayesian networks inherit from numerous research work about model-based diagnosis among which some of them exploit probabilities. Moreover, lots of applications of bayesian networks concern medical diagnosis or diagnosis of small or complex devices. This paper set out in détail the interest of the graphical probabilistic model that we use in order to diagnose complex devices, and we compare it with other probabilistic models, that use or not bayesian networks.