

ISOLATION DE DEFAILLANCES PAR RESEAUX BAYESIENS AUGMENTES DE REX

FAILURE ISOLATION BY BAYESIAN NETWORK AUGMENTED WITH FEEDBACK

SIMON C., WEBER Ph., IUNG B.
CRAN Université de Lorraine CNRS UMR 7039
Bd des Aiguillettes 54509
Vandoeuvre les Nancy, France

PEYSSON F. C.
PREDICT SA
19 Av de la Forêt de Haye
Vandoeuvre les Nancy, France

Résumé

Dans le cadre d'un laboratoire commun entre l'entreprise PREDICT SA et le Centre de Recherche en Automatique de Nancy, tous deux spécialistes dans le domaine de la maintenance prévisionnelle et du PHM, la problématique de l'isolation de défaillance a été traitée à partir d'un réseau bayésien. Un réseau bayésien initiale dont la structure graphique est défini par des experts systèmes et paramétré pour tenir compte du REX obtenu par les équipes de maintenance. Chaque nouvellement événements est pris en compte pour ajuster les paramètres du réseau et guider efficacement les nouvelles recherche de cause de dysfonctionnement.

Summary

In the context of a joint laboratory between the PREDICT company a SME and the Research Centre on Automatic Control, both specialist in the area of provisional maintenance and PHM, the problematic of failure isolation has been dealt from a Bayesian network. An initial Bayesian Network is first defined by some system experts then parameterized from the feedback given by the maintenance team. Each new event is taken account to tune the Bayesian network parameters and to guide the next isolation of the root cause of the system malfunction efficiently.

1. Introduction

La société PREDICT et le Centre de Recherche en Automatique de Nancy (CRAN) tous deux spécialisés dans le domaine de la maintenance prévisionnelle et du PHM (Prognostics and Health Management), se sont associés dans un Laboratoire Commun (LabCOM), intitulé PHM-FACTORY. Ce laboratoire est financé par l'Agence Nationale de la Recherche (ANR) et les entités fondatrices dans le but de développer des outils et méthodes de PHM. Il s'agit d'un concept novateur clé du maintien en conditions opérationnelles de tout système industriel ou objet de services. Dans ce contexte, le LabCOM est amené à développer et transférer des éléments théoriques vers une mise en œuvre opérationnelle au sein des solutions logicielles proposées par PREDICT.

Dans cette activité collaborative, la société PREDICT a posé la problématique d'amélioration de l'isolation de défaillances pour une remise en conditions opérationnelles rapide des systèmes de ses clients. Le CRAN, face à cette problématique, a décidé d'investiguer une approche à la fois théorique et fonctionnelle, devant déboucher à terme sur une solution algorithmique intégrable dans le progiciel KASEM de PREDICT.

Dans la littérature, il existe de nombreuses méthodes d'isolation de défauts/défaillances. Elles font l'objet d'états de l'art réguliers [9]. La fonction diagnostic se décompose généralement en une détection du défaut indiquant l'occurrence d'une dérive de

fonctionnement au sein d'un système, une localisation du défaut précisant l'élément en défaut et une identification du type et de la sévérité du défaut [10]. Trois familles de méthodes de diagnostic peuvent être cependant mises en évidence comme il a été proposé par [2], [3], [4] (Figure 1) :

- L'une fondée sur la classification des comportements du système (PHB : Process History Based) plutôt dans une démarche bottom-up,
- Une seconde classe de méthodes fondées sur des modèles de connaissance quantitatifs (Quantitative Model-Based).
- La troisième classe de méthodes fondées sur des modèles issus de l'expertise humaine (Qualitative Model Based).

La société PREDICT, comme de nombreuses sociétés d'ingénierie et de service, effectue un travail d'analyse des systèmes techniques de ses clients. Dans le cadre de la problématique d'isolation de défauts, son activité relève de la troisième catégorie. L'expertise industrielle apportée par l'entreprise et ses clients aboutit à l'élaboration d'un arbre de diagnostic propre à chaque système. Ce digraph montre la causalité entre des causes de manière hiérarchique. C'est un guide visant à isoler la cause racine d'un défaut système pour y remédier par une intervention de maintenance.

L'inconvénient majeur d'un digraph est de rester par nature une analyse qualitative. En effet, en l'absence d'information quantitative indiquant l'importance d'une causalité, il n'y a pas la possibilité de donner la priorité à l'une des causes en particulier. L'objectif du travail

présenté ici est de combiner l'analyse qualitative et une analyse quantitative issue du travail mené par les équipes de maintenance lors de l'exploitation d'un arbre d'isolation. Pour cela, nous proposons d'exploiter la performance des réseaux bayésiens pour

combiner les relations causales et de l'information quantitative, tout en profitant de leur souplesse dans l'interaction avec les observations grâce à l'inférence bayésienne.

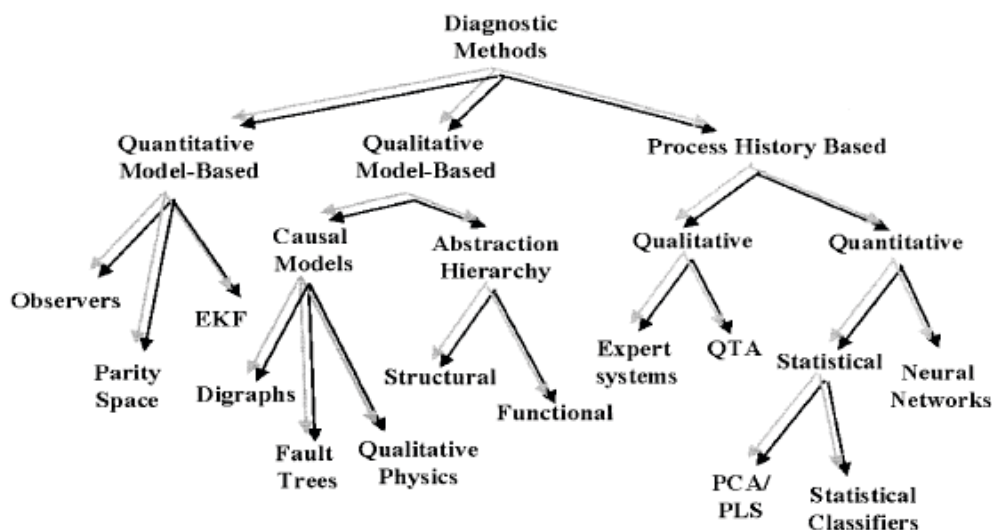


Figure 1 . Classification des méthodes de diagnostic

Les réseaux bayésiens fournissent un cadre formel de manipulation des évènements probabilistes en les représentant par des variables aléatoires discrètes [7] ainsi que les relations qui les lient en les représentant par des probabilités conditionnelles. Il existe un certain nombre de modèles basés sur les réseaux bayésiens qui sont utilisés dans le cadre de l'aide à la décision et notamment en diagnostic. Weber & Suhner proposent dans [6] une aide à la décision en maintenance par simulation de réseaux Bayésiens pour définir la meilleure politique pour chaque composant du système. Une autre application proposée par Medjaher [5] consiste en l'utilisation des réseaux Bayésiens statiques dans le domaine du diagnostic pour calculer les probabilités a posteriori de la ou des causes les plus probables d'une anomalie observée (observation ou évidence). Atoui et al. [1] exploite les principes de l'inférence bayésienne en combinant dans un réseau bayésien unique deux approches différentes, un système de diagnostic à base de données et un diagnostic à base de modèles. Celeux et al. [8] proposent également d'exploiter le retour d'expérience pour évaluer les probabilités dans un réseau bayésien modèle d'un système physique et ainsi ajuster la connaissance de ce système au fil du temps. Dans cette proposition, le modèle n'est pas déterministe a contrario de notre cas.

Par rapport à ce positionnement, notre objectif est, à partir d'un arbre déterministe d'isolation de défaillances fondé sur un arbre causal, de déterminer un réseau bayésien afin de profiter de son mécanisme d'inférence pour l'isolation de défaillances selon les connaissances liées à l'existence ou non d'une cause. Le retour d'expérience en ligne fourni par les équipes de maintenance permet l'estimation des probabilités d'occurrence des causes dans le réseau et d'améliorer le processus d'isolation de la prochaine défaillance en exploitant le moteur d'inférence bayésienne.

L'article est structuré comme suit. La section 2 rappelle quelques bases des réseaux bayésiens utiles à notre problématique. La section 3 définit la méthodologie proposée. La section 4 illustre la proposition sur un cas type anonymisé, d'une complexité raisonnable et sans perte de généralité.

2. Éléments fondamentaux des réseaux bayésiens

Un réseau bayésien est un graphe dirigé sans circuit représentant des dépendances et indépendances entre des variables aléatoires. C'est aussi une représentation compacte d'une distribution de probabilités jointes sur des évènements. Un réseau bayésien est basé sur un ensemble de nœuds représentant les variables aléatoires de la connaissance modélisée et des arcs orientés indiquant le lien

entre les variables. Les nœuds racines du réseau contiennent des distributions de probabilités *a priori* sur les états possibles des variables représentées, les nœuds enfants contiennent des probabilités conditionnelles caractérisant la force de la relation probabiliste entre les variables.

Un réseau bayésien peut ainsi être représenté de manière formelle comme un graphe $G = \langle (N, A), (P_r, P_c) \rangle$ avec N l'ensemble des nœuds, A l'ensemble des arcs, P_r l'ensemble des probabilités racines et P_c l'ensemble de probabilités conditionnelles. La forme mathématique proposée ici est légèrement plus précise que celle proposée initialement dans [11] ou encore l'expression mathématique donnée dans [12] :

$$P(x_1, x_2, \dots, x_n) = \sum_{i=1}^n P(x_i | pa(x_i))$$

avec $pa(x_i)$ les parents de x_i

L'écriture proposée a pour objectif d'explicitement concrètement P_r , l'ensemble des probabilités *a priori* des nœuds racines, qui est à estimer en fonction du retour d'expérience fourni par les équipes de maintenance.

La structure du graphe (N, A) , est figée à partir de l'analyse du système et de la connaissance des experts. Il ne s'agit pas d'une analyse dysfonctionnelle, mais de la modélisation du diagnostic par une structure causale mettant en relation hiérarchique un ensemble de causes d'intérêt jusqu'à un niveau de granularité pertinent dans la recherche des causes racines du dysfonctionnement.

L'espace d'état des nœuds représentant les causes est réduit à deux états indiquant la présence ou l'absence de la cause. À cette étape du travail, il n'y a pas d'introduction de variables multi-état ou de variables continues. L'incertitude considérée est purement aléatoire par opposition à d'autres travaux sur la question de l'incertitude dans les réseaux probabilistes [16]. Les probabilités conditionnelles du réseau sont dans $\{0,1\}$ car la logique de causalité est par essence considérée stricte à l'opposé du travail de Celeux et al [8]. La logique de causalité proposée est soit un OU inclusif (Table 1) soit un OU exclusif (Table 2).

Le OU exclusif (Table 1) fait l'hypothèse que le dysfonctionnement n'est dû qu'à une seule cause. Cette hypothèse peut être vue comme restrictive, mais dans la pratique, l'équipe de maintenance sérialise ses recherches de causes.

Table 1 .TPC d'un OU exclusif

x_1	x_2	...	x_{n-1}	x_n	F	T
0	0	...	0	0	1	0
0	0	...	0	1	0	1
0	0	...	1	0	0	1
0	0	...	1	1	1	0
...
1	0	...	0	0	0	1
...
1	1	...	1	1	1	0

Table 2 . TPC d'un OU inclusif

x_1	x_2	...	x_{n-1}	x_n	F	T
0	0	...	0	0	1	0
0	0	...	0	1	0	1
0	0	...	1	0	0	1
0	0	...	1	1	0	1
...
1	0	...	0	0	0	1
...
1	1	...	1	1	0	1

Aussi, le réseau bayésien causal sert à tester des hypothèses de présence ou absence d'une cause et vérifier sur le terrain sa véracité. Si deux causes venaient à être présentes simultanément, alors elle serait traitée l'une après l'autre comme deux événements successifs sans perte de généralité. À noter toutefois l'importance de l'indépendance des événements qui doit être vraie dès la construction du graphe sans quoi les vérifications d'hypothèses sont très délicates voire impossibles.

Le processus d'isolation consiste en une succession de vérification d'hypothèses de présence d'une cause à partir d'observations sur le terrain. La confirmation ou l'infirmité de la présence d'une cause induit une actualisation des distributions de probabilités de l'ensemble des variables du réseau par inférence, apportant ainsi une nouvelle série d'hypothèses de présence de causes à vérifier jusqu'à l'isolation effective de la cause racine ou à défaut d'un arrêt de l'isolation à un niveau de finesse désiré. C'est cet atout majeur des réseaux bayésiens qui en a conditionné le choix pour cette application. À noter que les probabilités des causes conditionnées aux observations $P(x_i | x_j, \dots)$ s'apparentent au facteur d'importance de diagnostic de Vesely-Fussell [16]. C'est évidemment la cause la plus probable sur laquelle l'effort de maintenance va se porter.

L'élément clé restant pour la construction du réseau bayésien est maintenant de définir les probabilités *a priori* P_r de l'ensemble des nœuds racines. Lorsque l'on dispose d'une base de données conséquente et

représentative, l'estimation des probabilités peut être réalisée facilement. Éventuellement, des experts peuvent fournir des distributions ou des connaissances génériques tels des tables, des abaques ou des documents de référence pouvant alimenter ces éléments. Notre objectif est d'ajuster ces probabilités en fonction d'observations du terrain.

3. Méthodologie de résolution

Comme nous l'avons vu dans la section précédente, la logique causale liée à l'exercice d'isolation de défaillance est fondée sur un arbre d'isolation structuré selon une hiérarchie de relations causales. L'enjeu de la méthodologie de résolution est de construire un réseau bayésien G_0 isomorphe à l'arbre d'isolation fourni par les experts maintenance du système et de définir l'ensemble des probabilités (P_r, P_c) .

L'isomorphisme est trivial puisqu'il suffit de construire le réseau bayésien comme un arbre. Les probabilités P_c sont connues puisqu'il s'agit d'un arbre à relations déterministes (OU exclusif) telles que données dans la table 1. La connaissance des événements doit alors définir les valeurs des probabilités P_r à partir du retour d'expérience en ligne.

Le graphe initial $G_0 = \langle (N, A), (P_c, P_r^0) \rangle$ est défini avec un jeu de probabilités racines initiales P_r^0 . Plusieurs types de distributions de probabilités peuvent être choisis. En l'absence de connaissance, des distributions uniformes peuvent être considérées. Des experts peuvent également fournir cette information. Éventuellement une distribution aléatoire, même si cela apparaît peu naturel ou encore une distribution Dirichlet, Haldane, Jeffreys ...[8].

L'occurrence d'une défaillance du système va être isolée à l'aide du réseau G_0 . Grâce à l'inférence bayésienne, les causes immédiates les plus probables sont calculées, les inspections lancées et leur conclusion injectée comme des observations dans le réseau G_0 . La cause trouvée est soit une cause racine et l'opération de maintenance est exécutée soit une cause intermédiaire et une recherche en profondeur est éventuellement démarrée jusqu'à l'obtention d'une isolation satisfaisante donnant lieu à une opération de maintenance. L'ensemble des données d'isolation obtenues est alors intégré pour définir une nouvelle distribution de probabilité P_r^1 . Chaque nouvelle phase d'isolation $n - 1$ permet la définition de la prochaine distribution P_r^n .

Le passage du jeu d'information d'isolation à la distribution P_r^i n'est cependant pas trivial. En effet, le jeu d'information est une information conditionnelle puisque l'on déroule une chaîne causale depuis l'évènement sommet jusqu'au niveau où l'information est certaine (observation). Nous sommes donc capables de calculer un estimateur de distributions conditionnelles $\theta^i(C_i|C_j)$ à partir de l'information retournée selon l'équation suivante :

$$\theta^i(C_i|C_j) = \frac{\|C_i\|+1}{\|C_j\|} \quad \{1\}$$

avec C_j la conséquence de C_i et $\|C_j\|$ le cardinal de C_j depuis l'instant 0.

A partir des estimateurs (eq. 1) révisés pour chaque nouvelle information, il s'agit de déterminer l'ensemble des probabilités P_r^i du réseau telles que $P_r^i(C_i|C_j) = \theta^{i-1}(C_i|C_j)$. Ceci peut être formulé comme un problème d'optimisation :

$$P_r^i(C_i) = \arg \min_{\sum_{P_r^i(C_i|C_j)} |P_r^i(C_i|C_j) - \theta^{i-1}(C_i|C_j)|} \quad \{2\}$$

avec $0 \leq P_r^i, \theta^i \leq 1$

Ce problème d'optimisation non-linéaire sous contrainte peut être résolu de plusieurs manières. Dans [17], un algorithme génétique a été utilisé avec le désavantage majeur d'un temps de calcul long qui peut être parfois incompatible avec le temps du process industriel et un résultat qui est approximatif. En ce sens, une minimisation par la méthode du point intérieur [15] peut être utilisée. Elle a l'avantage de donner des résultats assez précis en un temps souvent plus court, mais peut être sensible au point de départ.

La méthodologie de construction en ligne de l'arbre d'isolation de défaillances par réseau bayésien suit la méthodologie générique décrite dans la figure 2.

4. Illustration

Illustrons la méthodologie proposée sur un exemple industriel anonymisé pour des raisons de confidentialité. Seule la structure du graphe correspond à une réalité industrielle, les valeurs numériques sont purement arbitraires. Soit l'arbre d'isolation donné à la figure 3. Il s'agit d'un arbre à 3 niveaux hiérarchiques de causes. L'évènement redouté (la défaillance du système) nommé ER est la conséquence d'une cause parmi 4 (C1, C2, C3, C4). C1 est une cause racine. La cause intermédiaire C3 est elle-même la conséquence de deux causes C31 et C32. C4 a trois causes racines C41 à

C43. La cause C2 est bien décrite par les experts. Elle offre un arbre complexe avec deux sous-niveaux. Ses premières causes sont C21 à C23 avec C21 une cause racine, et C22, C23 deux causes décrites par deux causes racines chacune, C221 et C222 (resp. C231, C232).

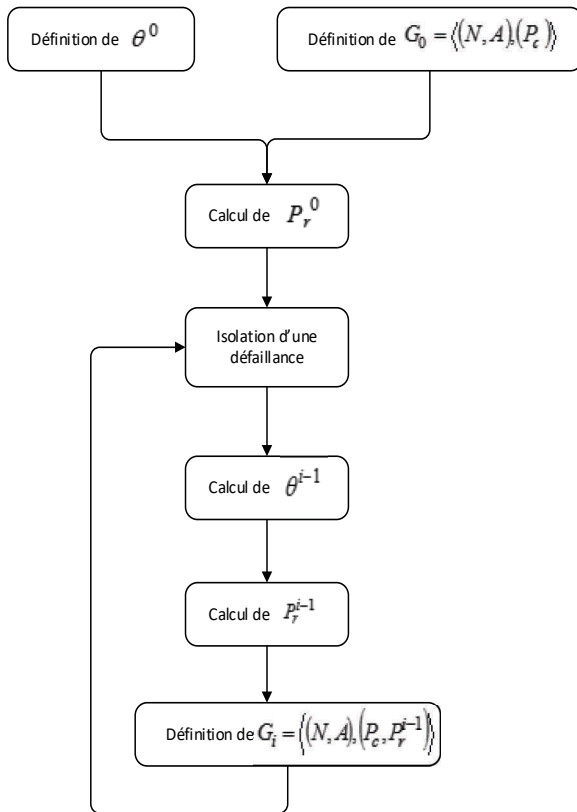


Figure 2. méthodologie générique

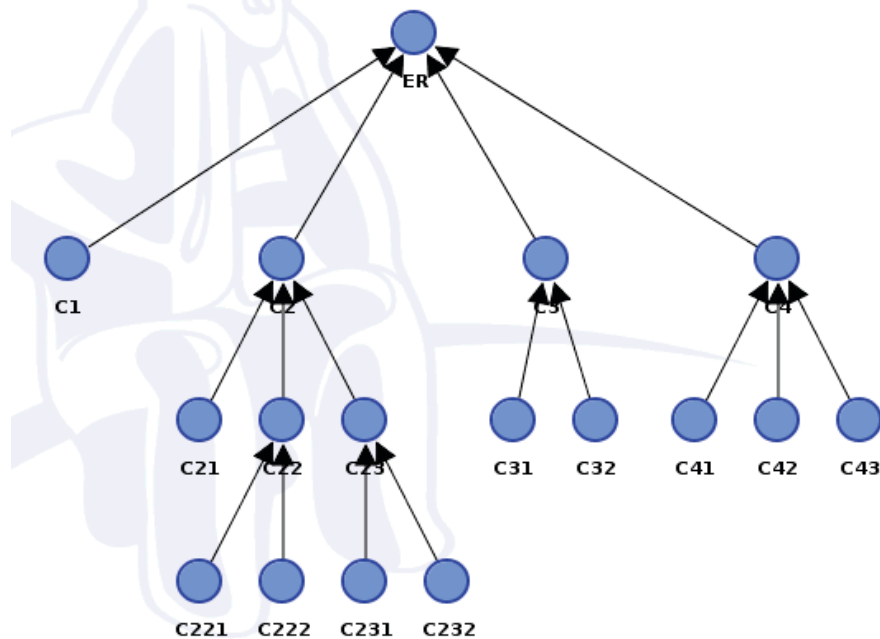


Figure 3 : Réseau bayésien d'isolation de défaillances.

Les TPC déterministes des nœuds enfants sont de type OU exclusif (Table 1). Sous l'hypothèse que la distribution initiale des θ soit uniforme, cause par cause, la figure 4 montre le graphe G_0 obtenu à l'aide de l'optimisation avec sur la partie droite de la figure l'observation d'un événement sur ER et l'isolation de la cause C4. Cela permet d'observer que les 3 causes C41 à C43 sont bien équiprobables comme attendu.

Pour montrer le fonctionnement et les résultats de la méthodologie sur l'arbre de la figure 3, nous avons exploité un REX d'isolation. Pour des raisons de confidentialité, les valeurs sont arbitrairement définies dans la table 3. Nous partons d'une distribution uniforme sur les P_r^0 et l'estimation de θ^i et P_r^i est construite sur la base des événements du REX.

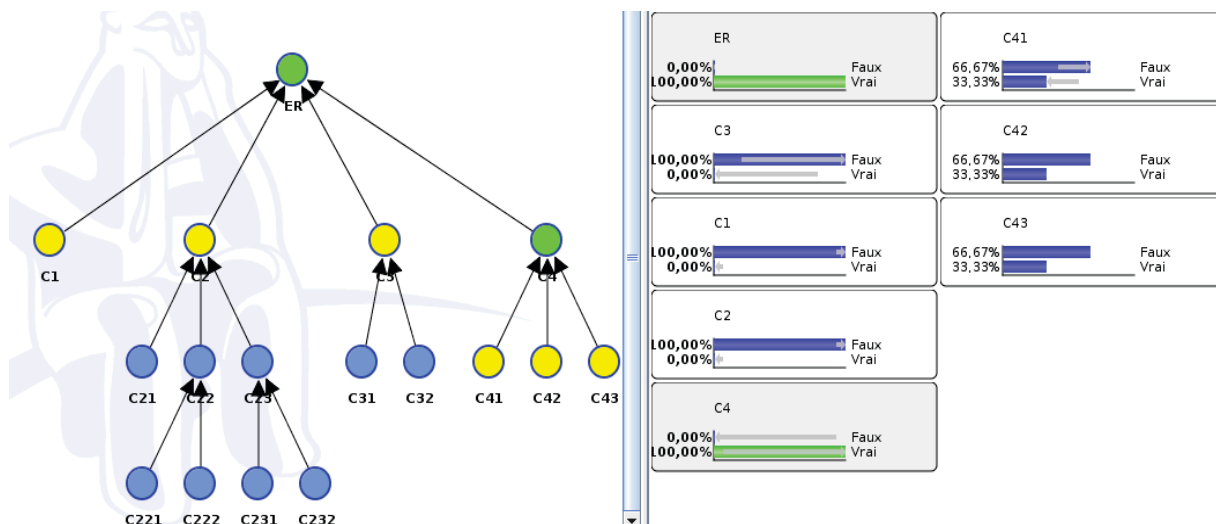


Figure 4 : Graphe G_0 avec isolation d'une cause racine de niveau 2

Table 3 : Probabilités du REX.

$P(C1 ER), P(C2 ER), P(C3 ER), P(C4 ER)$	0.4, 0.25, 0.25, 0.1
$P(C21 C2), P(C22 C2), P(C23 C2)$	0.7, 0.2, 0.1
$P(C31 C3), P(C32 C3), P(C41 C4), P(C42 C4), P(C43 C4)$	0.8, 0.2, 0.6, 0.3, 0.1
$P(C221 C22), P(C222 C22), P(C231 C23), P(C232 C23)$	0.8, 0.2, 0.7, 0.3




Figure 5 : Séquence de REX

La figure 5 montre une séquence de REX qui a été générée à partir du jeu de probabilités donné dans la table 3. Comme nous pouvons le constater, l'évènement C1 est le plus probable et les évènements racines les plus profonds (C221, C222, C231, C232) sont

faiblement présents. Toutefois, en relation avec la chaîne causale des évènements, l'ensemble des évènements d'une branche comme celle de C2 représente une probabilité élevée (0.25).

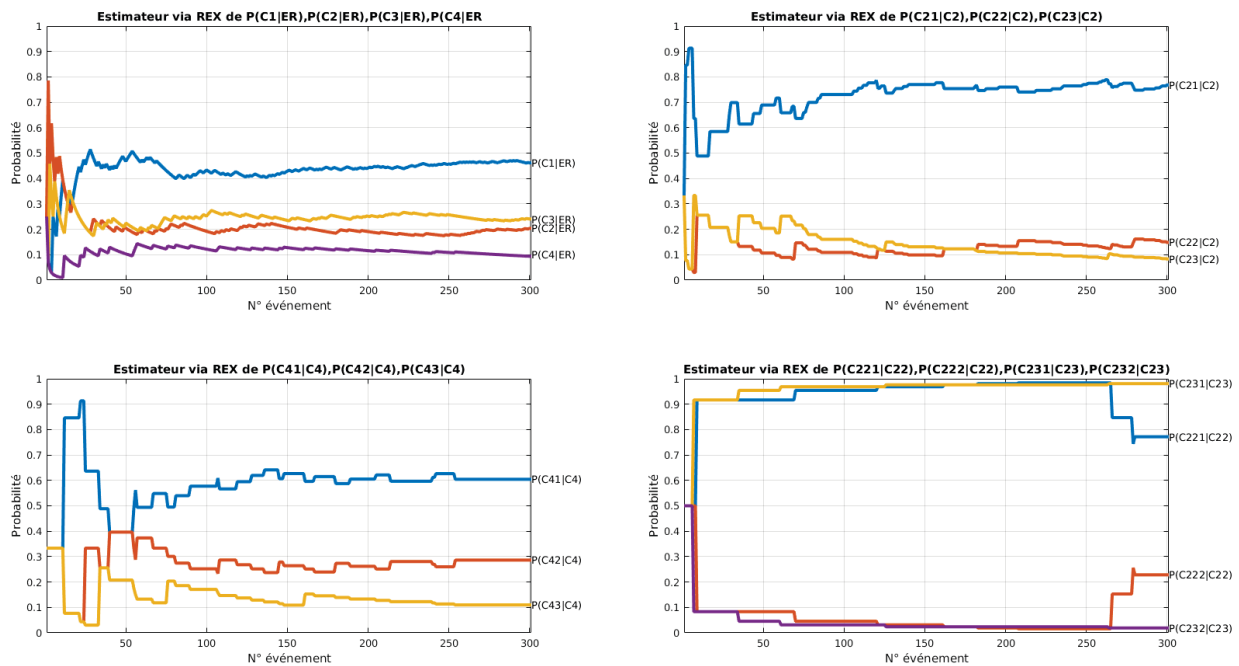


Figure 6. Evolution des estimateurs θ à partir du REX

La figure 6 montre l'évolution de l'estimateur de la probabilité d'occurrence de chaque évènement au fur et à mesure des évènements (observations) apparaissant dans le REX. Les évènements les plus hauts de l'arbre ont beaucoup de données et les probabilités évoluent pour converger vers les probabilités réelles (cf. Table 3). Les estimateurs de probabilités des évènements de niveau 2 (C21 à C43) sont basés sur moins d'observations. Selon les branches de l'arbre sollicitées par chaque élément du REX, l'évolution des estimateurs est plus lente et des plateaux apparaissent en l'absence d'observations. La convergence vers les valeurs s'opère également, mais avec une vitesse plus lente que pour les éléments de haut niveau. Cela s'observe de manière flagrante au niveau 3 de l'arbre d'isolation, en bas à droite de la figure 6.

La méthodologie proposée consiste ensuite à estimer les valeurs des probabilités a priori à mettre dans les nœuds racines de l'arbre pour que les probabilités a posteriori soient égales aux estimateurs. C'est l'outil d'optimisation qui remplit cette fonction (cf eq. 2). La figure 7 montre l'évolution des probabilités a posteriori pour les évènements C1 à C4 en haut de la chaîne causale (courbes de gauche) à partir des probabilités a priori obtenue par le processus d'optimisation (courbes de droite).

Le résultat final c'est-à-dire les valeurs vers lesquelles convergent les distributions de probabilités issues de l'arbre d'isolation instancié sur chaque évènement du REX est indépendant du point de départ. Les figures 8

à 10 montrent l'évolution des 4 estimateurs C1 à C4 sur des scénarios de REX différents, mais issus du même jeu de probabilité (table 3) avec un point de départ qui est soit un jeu de valeurs aléatoires, soit un jeu uniforme soit une valeur d'experts.

Comme nous pouvons le constater sur les figures 8, 9 et 10, les valeurs initiales jouent un rôle important sur le début de la phase d'estimation, mais leur contribution se réduit au fur et à mesure du REX d'évènements. Rappelons que les REX sont différents pour chaque figure, mais issus d'un tirage aléatoire statistiquement identique et conforme à la table 3.

5. Conclusion

La méthodologie proposée a permis de convertir un graphe causal déterministe simple en un outil probabiliste d'aide à l'isolation de fautes et défaillances. Le REX fourni par l'équipe de maintenance sert à affiner les probabilités du modèle probabiliste (réseau bayésien) pour augmenter l'efficacité de la phase d'isolation.

La validité de l'approche a été vérifiée sur des scénarios de simulation et sur des données réelles.

Nous disposons donc d'une méthodologie opérationnelle qui, en outre, est implantée dans l'outil KASEM de PREDICT, outil dédié aux processus du PHM et à la e-maintenance (Figure 11.)

Les domaines d'application sont multiples en maintenance et la méthodologie a d'autant

plus d'intérêts que le système est complexe et de grande taille en nombre d'évènements et en profondeur de relations causales.

6. Références

[1] Atoui, M. A., Verron, S., and Kobi, A. (2016). A bayesian network dealing with measurements and residuals for system monitoring. Transactions of the Institute of Measurement and Control, 38(4):373–384.

[2] V. Venkatasubramanian, R. Rengaswamy, K. Yin, et S. N. Kavuri, « A review of process fault detection and diagnosis: Part I: Quantitative model-based methods », Comput. Chem. Eng., vol. 27, no 3, p. 293 - 311, mars 2003.

[3] V. Venkatasubramanian, R. Rengaswamy, et S. N. Kavuri, « A review of process fault detection and diagnosis: Part II: Qualitative models and search strategies », Comput. Chem. Eng., vol. 27, no 3, p. 313 - 326, mars 2003.

[4] V. Venkatasubramanian, R. Rengaswamy, S. N. Kavuri, et K. Yin, « A review of process fault detection and diagnosis: Part III: Process history based methods », Comput. Chem. Eng., vol. 27, no 3, p. 327 - 346, mars 2003.

[5] K. Medjaher, A. Mechraoui, N. Zerhouni, "Diagnostic et pronostic de défaillances par réseaux bayésiens". Journées Francophone sur les Réseaux Bayésiens, 2008, Lyon, France.

[6] P. Weber, M.C. Suhner, Aide au choix de stratégie de maintenance par simulation de réseaux bayésiens. QUALITA 2001, Annecy, France, 22-23 Mars.

[7] F.V. Jensen, An Introduction to Bayesian Networks. (UCL Press (Ed)). London, 1996.

[8] Celeux, G., Corset, F., Lannoy, A., and Ricard, B. (2006). Designing a bayesian network for preventive maintenance from expert opinions in a rapid and reliable way. Reliability Engineering & System Safety, 91(7):849 – 856.

[9] Andreas Varga, Solving Fault diagnosis problems, 2017

[10] Rapport Technique IMdR P15-2 : HUMS-PHM, 2017

[11] Jensen, F. V. and Nielsen, T. D. (2007). Bayesian Networks and Decision Graphs. Springer New York.

[12] Pearl, J. Probabilistic reasoning in intelligent systems: networks of plausible inference Morgan Kaufmann Publishers Inc., 1988

[13] Lampis, M. (2010). Application of Bayesian Belief Networks to system fault diagnostics. PhD thesis, Loughborough University.

[14] Lauria, E. J. and Duchessi, P. J. (2006). A bayesian belief network for IT implementation decision support. Decision Support Systems, 42(3):1573 – 1588.

[15] Byrd, R. H., J. C. Gilbert, and J. Nocedal. "A Trust Region Method Based on Interior Point Techniques for Nonlinear Programming." Mathematical Programming, Vol 89, No. 1, 2000, pp. 149–185

[16] Simon, C.; Weber, P. & Sallak, M. Data Uncertainty and Important Measures John Wiley & Sons, 2018

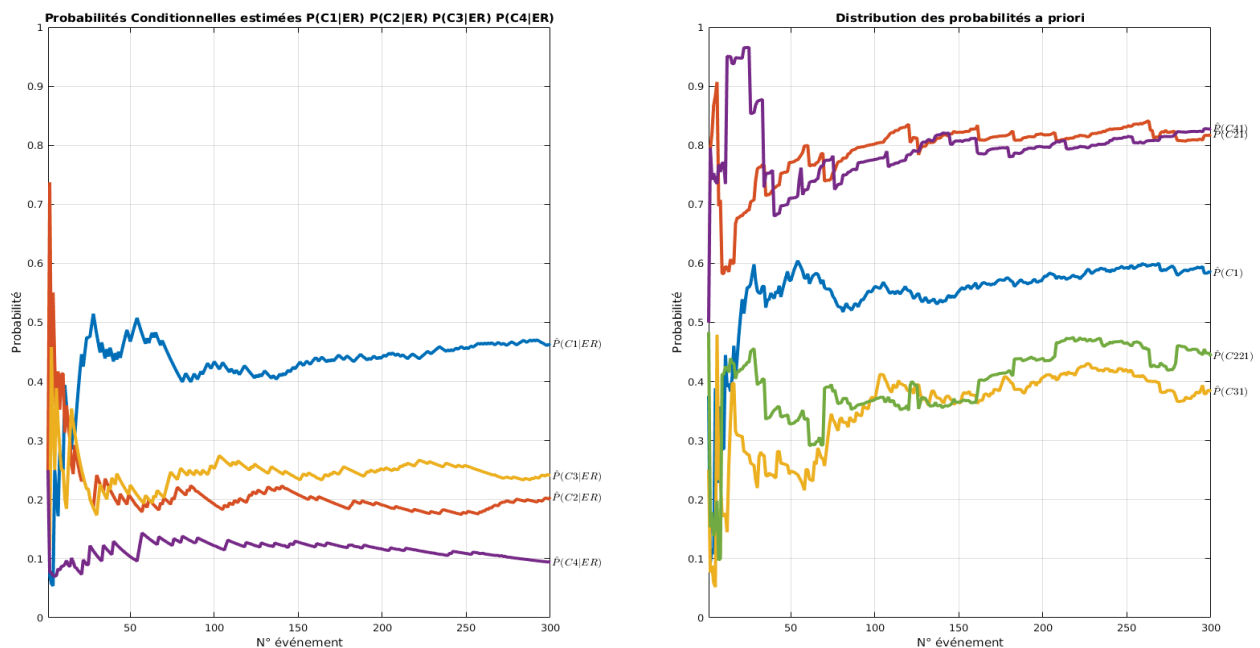


Figure 7 . Evolution des probabilités a priori et a posteriori issue du RB

[17] Mechri, W.; Simon, C. & Morel, D. Retour d'expérience et modèle graphique probabiliste pour l'isolation de défaillances 12eme congrès international pluridisciplinaire en Qualité, Sûreté de Fonctionnement et Développement Durable, 2017

Nationale de la Recherche - Réf: ANR-15-LCV1-0005-01. En ce sens, nous souhaiterions remercier toutes les entités qui sont impliquées dans ce LabCOM et plus précisément la PME PREDICT, l'ANR, le pôle de compétitivité MATERIALIA, le CRAN, le CNRS et l'Université de Lorraine.

7 Remerciements

Ces travaux ont été réalisés dans le cadre du LabCOM ANR nommé PHM-FACTORY soutenu par l'Agence




Figure 8 . Estimation avec initialisation aléatoire

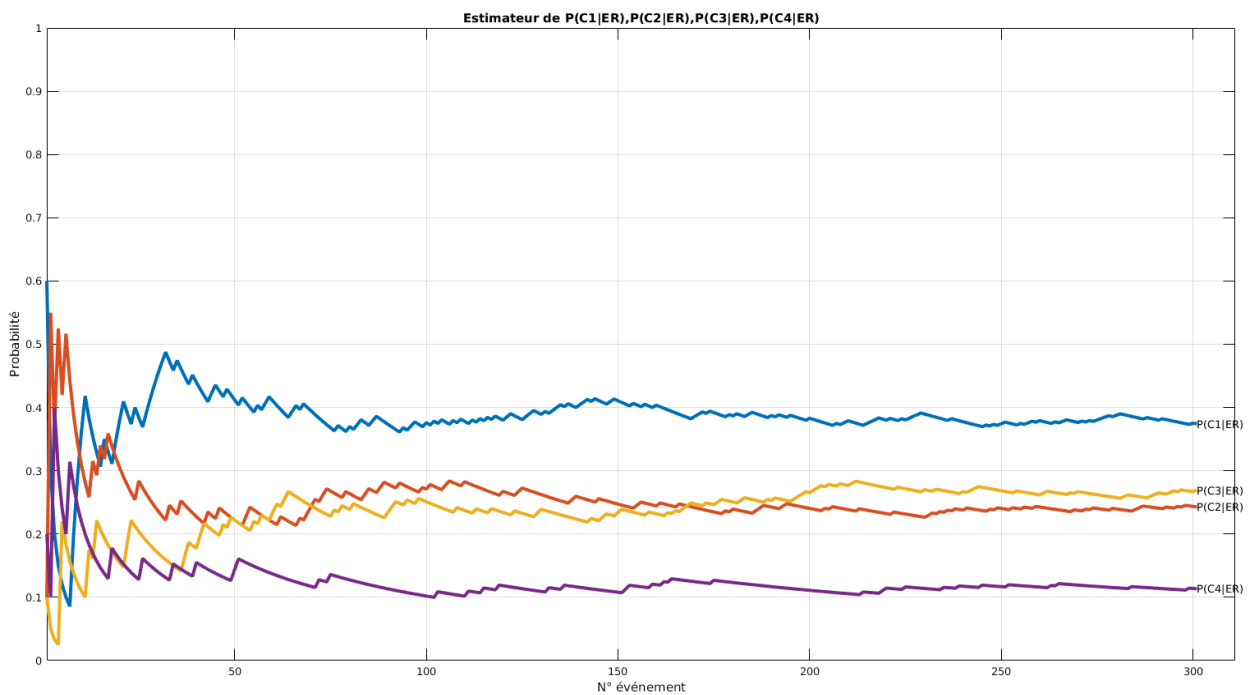


Figure 9. Estimation avec valeurs initiales uniformes

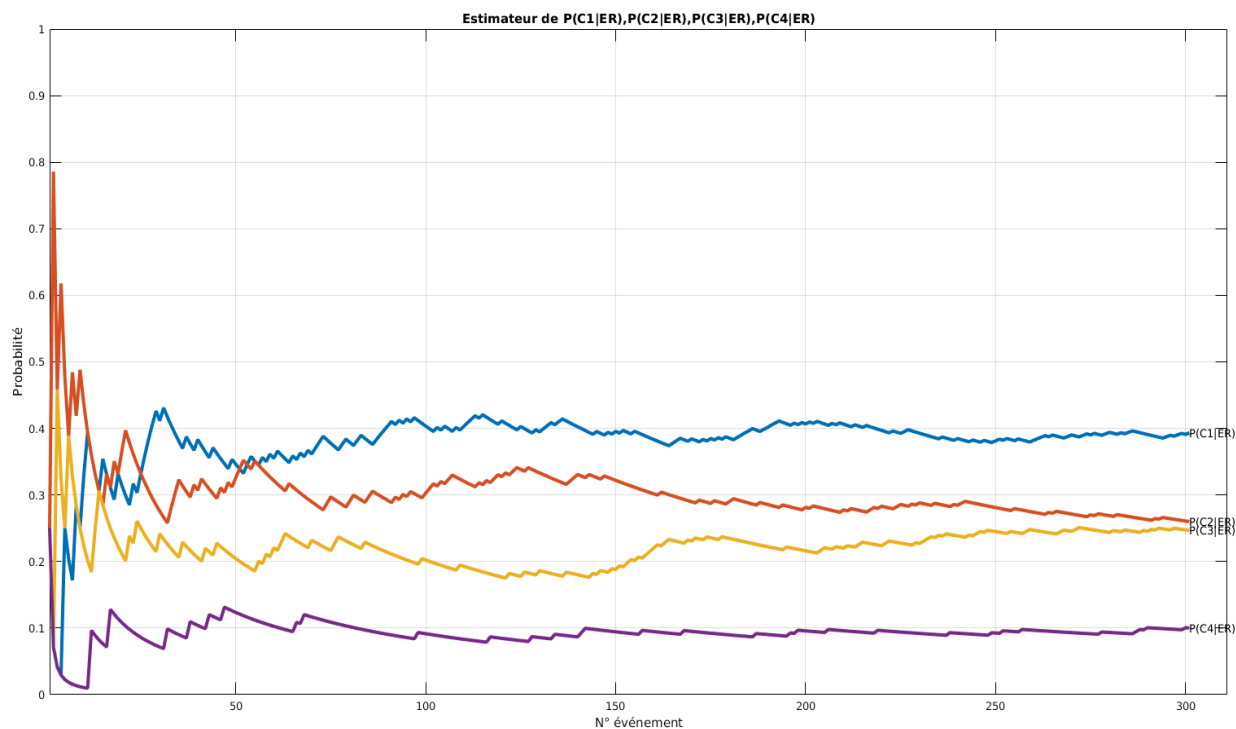


Figure 10 . Estimation avec valeurs initiales données par un expert.

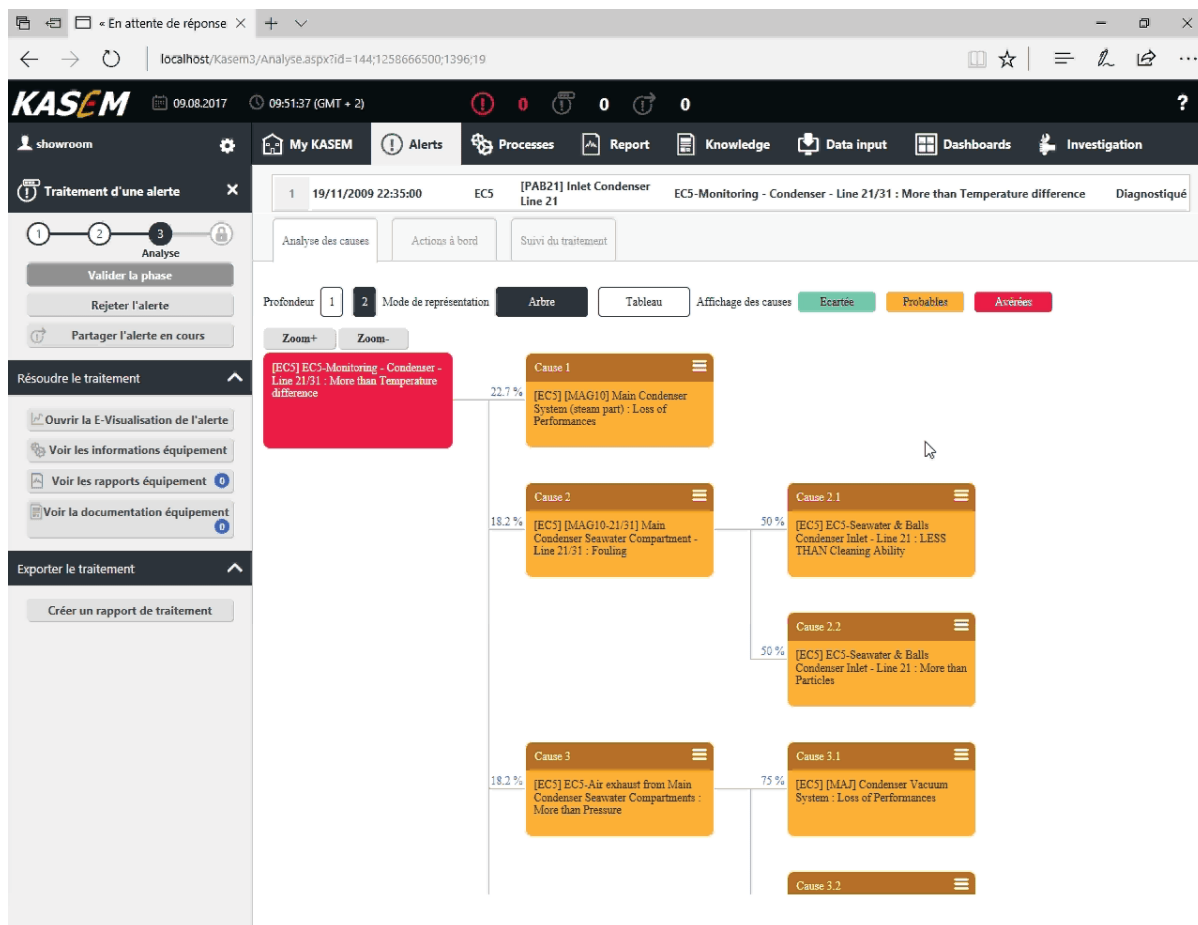


Figure 11 . Interface intégrée dans KASEM