

Génération de composant "état de santé" pour monitorer le système embarqué de véhicule autonome*

Sara Zermani, Catherine Dezan, Chabha Hireche, Reinhardt Euler et Jean-Philippe Diguet

Université de Bretagne Occidentale/Sud,
Lab-STICC, CNRS UMR 6285
Brest/Lorient- France
Sara.zermani@univ-brest.fr

Résumé

Le but de cet article est de proposer une méthode pour l'évaluation probabiliste de l'état de santé des véhicules autonomes. Basées sur des informations de capteurs, les causes d'erreurs des composants peuvent être observées dans certains contextes spécifiques. Notre modèle repose sur la construction d'un réseau bayésien de l'état de santé à partir de l'analyse des modes de défaillances et leurs effets. Une implémentation matérielle/logicielle (HW/SW) du module "état de santé" est également proposée, pour un calcul en ligne et en temps réel sur une plate-forme embarquée incorporant un circuit hybride.

Mots-clés : Etat de santé, réseaux bayésiens, FPGA, synthèse matérielle, FMEA.

1. Introduction

Les systèmes autonomes, tels que les drones, sont de plus en plus complexes. En outre, ils opèrent dans des environnements incertains et doivent faire face à des obstacles inattendus, des changements climatiques et des défaillances matérielles ou logicielles. Un léger dysfonctionnement peut avoir des conséquences désastreuses. Il est alors nécessaire d'évaluer continuellement l'état de santé du système pour vérifier la fiabilité de la mission et pouvoir agir en temps réel, dans le but de prendre des décisions (replanification, reconfiguration, etc.) qui maximisent les capacités à répondre aux objectifs de la mission, tout en maintenant les exigences de sécurité.

Un tel système d'évaluation de l'état de santé se base sur des méthodes de diagnostic. Ces méthodes ont pour objectif de détecter et de localiser la ou les défaillances, à l'aide d'observations sur le système et d'un modèle représentant les relations causales entre ses composants. Plusieurs modèles peuvent être envisagés tels que les réseaux de neurones, les systèmes experts, les modèles d'analyse de données, les arbres de défaillances, les modèles logiques, les réseaux bayésiens, etc. . Une tableau comparatif entre ces modèles est donné dans [2]. Dans notre cas, nous avons choisi les réseaux bayésiens qui sont les plus adaptés pour faire face à l'incertitude. Dans cet article, nous proposons dans un premier lieu une nouvelle approche probabiliste pour l'évaluation de l'état de santé de systèmes autonomes, basée sur des réseaux bayésiens. Ces réseaux sont largement utilisés pour mettre en œuvre le diagnostic dans divers

*. Article présenté à Compas'2016

types de systèmes [14, 5]. Notre approche a la particularité de construire les réseaux bayésiens à partir de l'Analyse des Modes de Défaillances et leurs Effets (FMEA [1]) et leurs contextes d'apparition. En deuxième lieu, nous proposons une implémentation de l'état de santé des systèmes pour un contexte embarqué. Nous présentons une implémentation HW/SW du calcul de l'état de santé, sur un dispositif hybride pour un calcul en ligne et en temps réel. Ces implémentations contribuent à l'adaptation de l'implémentation en fonction des contraintes de performances et de la disponibilité des ressources.

Cet article est organisé comme suit. La section 2 présente les réseaux bayésiens pour le diagnostic et expose notre approche basée sur une analyse de type FMEA. La section 3 illustre l'approche sur des cas d'étude, la géolocalisation par GPS, et la consommation énergétique. Dans la section 4, l'implémentation HW/SW embarquée est présentée. La section 5 est consacrée à la discussion des différentes expériences et résultats pour conclure et faire le point sur les perspectives.

2. Modèle de réseau bayésien pour l'évaluation de l'état de santé

2.1. Les réseaux bayésiens pour le diagnostic et l'état de santé d'un système

Les réseaux bayésiens sont des modèles graphiques probabilistes utilisés pour comprendre et contrôler le comportement des systèmes [14]. Les variables sont représentées comme des nœuds d'un graphe orienté acyclique (DAG) et les dépendances conditionnelles entre les variables sont représentées comme des arcs. Les nœuds ont un nombre fini d'états et sont associés à des tables de probabilités conditionnelles (CPT) représentant les relations entre les nœuds et leurs parents.

Pour faire face à l'incertitude, les réseaux bayésiens sont largement utilisés pour mettre en œuvre le diagnostic complexe dans divers types de systèmes [7]. Le lecteur peut se référer aux documents représentatifs suivants. Dans [13], les auteurs proposent une étude sur la validation du capteur avec les réseaux bayésiens pour la surveillance structurelle de la santé. L'étude [3] présente un réseau bayésien pour un système spécifique de surveillance et de contrôle d'une borne de terre par satellite, et la fiabilité des systèmes logiciels pour la surveillance des applications électriques avec des réseaux bayésiens est abordé dans [15].

2.2. Une approche basée sur l'analyse de type FMEA et le modèle réseau bayésien associé

L'analyse FMEA est une méthode pour identifier les modes de défaillance d'un produit ou d'un processus. Elle permet d'identifier pour l'ensemble des couples {composant, fonction}, les modes de dégradation de la fonction considérée, les causes de ces modes de dégradation et leurs conséquences sur le système étudié [1].

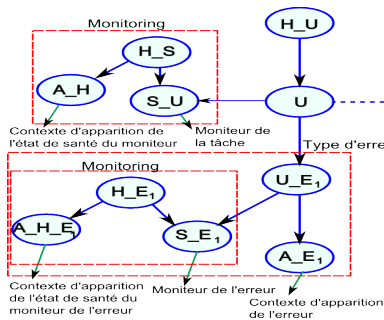
La table 1 résume le résultat de cette analyse où U_{E_i} représente un type d'erreur source de défaillance. Cette défaillance est monitorée par des contextes d'apparition A_{E_i} et (ou) des capteurs S_{E_i} qui peuvent être matériels ou logiciels. Ces capteurs peuvent eux-mêmes être défaillants, information pouvant être aussi renforcée par des contextes d'apparition (A_H ou $A_{H_{E_i}}$) sur l'état de santé de ces capteurs (H_S ou H_{E_i}).

Type d'erreur	Monitoring	Contexte d'apparition
U_{E_i}	Capteur S_{E_i}	A_{E_i}

TABLE 1 – Analyse de type FMEA pour déterminer l'état de santé associé à un type d'erreur

Cette table peut être traduite sous forme de réseau bayésien en respectant le principe de la D-séparation [2] pour la circulation de l'information. Le réseau bayésien obtenu est représenté

dans la figure 1 avec les différents types de nœuds.



- **Nœud H** : reflète l'état de santé du sous-système (H_U) ou des capteurs (H_S ou H_E).
- **Nœud S** : indique les mesures de traitement au moyen de capteurs HW/SW du sous-système (S_U) ou des erreurs (S_E).
- **Nœud U** : reflète l'état 'inobservable' du sous-système ou du composant (U) ou des erreurs (U_E).
- **Nœud A** : reflète le contexte d'apparition des erreurs (A_E) ou de l'état de santé de capteurs (A_H ou A_H_E).

FIGURE 1 – Modèle générique pour l'état de santé à partir d'une analyse de type FMEA

Les entrées du modèle sont les valeurs des capteurs qui représentent les états observables (évidences). Les nœuds «contexte d'apparition» peuvent aussi être observables pour renforcer la croyance sur l'erreur ou sur l'état de santé des capteurs. La sortie du modèle est la probabilité a posteriori de l'état de santé du sous-système (nœud H_U) par rapport aux évidences données.

3. Etude de cas

Dans cette section, deux exemples d'application du modèle sont proposés, une modélisation de la position donnée par le GPS et la consommation énergétique. Deux cas critiques et importants dans le cas d'un véhicule autonome.

3.1. Cas de la position donnée par le GPS

Pour calculer la position avec le GPS, il suffit de connaître des positions de référence (positions des satellites) et leurs distances par rapport au récepteur GPS [8]. Cette distance est calculée en multipliant le temps de propagation du signal par sa vitesse. Les signaux doivent traverser les différentes couches de l'atmosphère (ionosphère et troposphère) pour arriver au récepteur. Par conséquent, les signaux sont réfractés par des particules chargées d'atomes, de molécules, ... ; ce qui impacte sur la direction et la vitesse de propagation du signal. En plus de ces deux causes, on retrouve aussi l'horloge satellite, l'éphéméride, le multipath et les erreurs du récepteur. La figure 2 représente les erreurs GPS et la table de l'analyse de type FMEA correspondante [11].

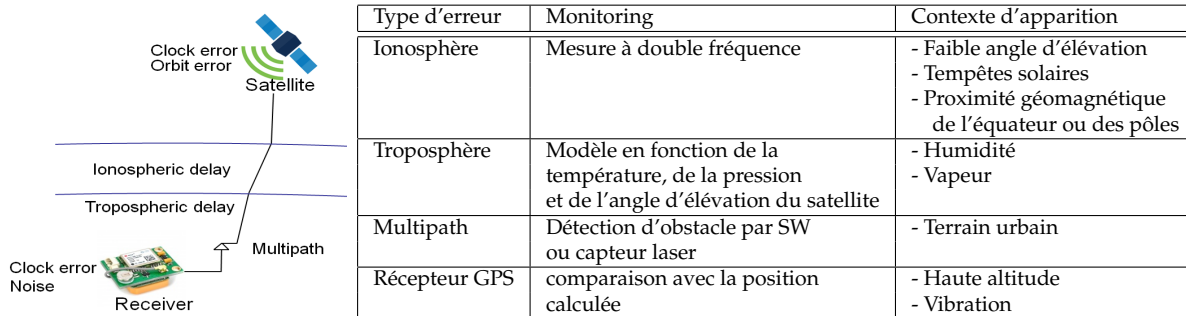


FIGURE 2 – Les erreurs GPS et la table de l'analyse de type FMEA correspondante

3.2. Cas de la consommation énergétique

La consommation énergétique évolue d'une manière linéaire dans le mode nominal (sans perturbation ou événement interne/externe). Les événements extérieurs tels que le vent peuvent

augmenter la consommation d'énergie, ainsi que toute autre application/composant utilisés dans la période de temps. Le niveau d'énergie est donné par un capteur, qui peut être défaillant. La croyance sur la fiabilité de ce capteur peut être renforcée par les contextes d'apparition (la température, par exemple).

3.3. Modèles réseaux bayésiens

Les modèles du GPS et de l'énergie sont donnés dans les figures 3 et 4. Pour le cas du GPS, en se basant sur le modèle générique proposé, le sous-système est évalué par les 4 types d'erreur, qui eux-mêmes sont monitorés par des capteurs logiciels ou matériels et leurs contextes d'apparition. Les capteurs de monitoring eux-mêmes peuvent être défaillants, cette information est renforcée par le nœud contexte d'apparition "météo" (cas ciel nuageux) dans le cas du capteur laser pour la détection du multipath, par exemple. Pour le cas de l'énergie, le réseau bayésien est dynamique sur deux temps (2TBN), car le niveau de l'énergie à un instant t dépend des tâches de l'instant $t - 1$. La partie intra-slice du modèle correspond au modèle générique, et se construit de la même manière que pour le GPS avec les événements internes/externes comme types d'erreurs. Les nœuds "commande" (C) représentent l'activation des applications/composants externes, et peuvent modifier la consommation. La partie interslice du modèle représente l'évolution du réseau entre deux temps (slice 0, slice 1). L'état de l'énergie (nœud U_Energy) à l'instant t est liée à l'état de l'énergie à l'instant $t + 1$ à travers des nœuds observables (événements externes et applications qui modifient l'état de l'énergie à l'instant $t + 1$).

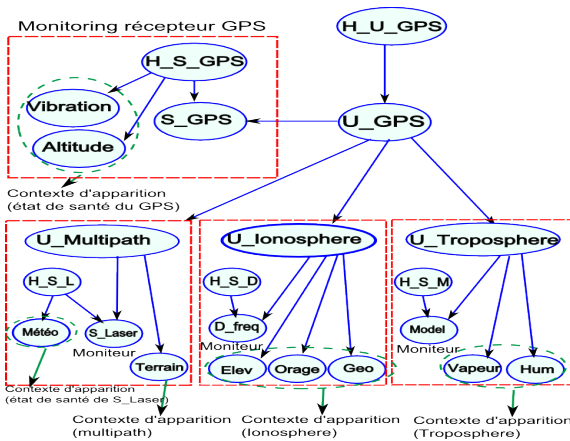


FIGURE 3 – Réseau bayésien pour l'état de santé de la position par GPS

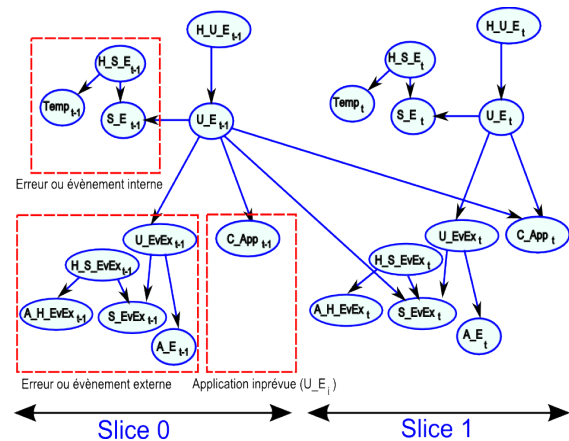


FIGURE 4 – Réseau bayésien pour l'état de santé de l'énergie

4. Génération de l'état de santé pour un contexte embarqué

Pour évaluer l'état de santé du système pour un tel modèle, on calcule la probabilité a posteriori du nœud H_U du réseau bayésien par rapport aux observations (évidences). Cette approche est dite l'inférence bayésienne. Les algorithmes classiques d'inférence sont basés sur la propagation en arbre de jonction [9], mais un problème majeur pour les systèmes embarqués est la complexité des calculs. Divers travaux ont été consacrés à l'inférence bayésienne en termes d'accélération de calcul, par la mise en œuvre d'implémentations matérielles [19, 10]. Compiler un réseau bayésien vers un circuit arithmétique (AC) est une méthode efficace pour les systèmes embarqués afin de minimiser les ressources et les performances [16, 6].

Dans cette section, après une présentation de l'inférence par AC, un atelier logiciel pour l'implémentation de notre modèle bayésien pour l'évaluation de l'état de santé d'un système est introduit. Pour générer les composants de santé, une approche modulaire et hiérarchique du calcul d'inférence est adoptée.

4.1. L'inférence par AC

La méthode de l'inférence par AC se base sur les fonctions multilinéaires (MLF). Pour chaque réseau bayésien, une MLF unique est définie, avec deux types de variables :

- λ_x (indicateurs d'évidence) : l'ensemble des évidences.
- $\theta_{x|u}$ (Paramètres du réseau) : les valeurs de probabilité associées aux variables X et U .
- \sim désigne la relation de compatibilité entre les instantiations [6].

$$f = \sum_x \prod_{x|u \sim x} \lambda_x \theta_{x|u} \quad (1)$$

La fonction f représente les différentes probabilités marginales. Cette fonction est représentée en un arbre (AC), un exemple est donné dans la figure 5. Les feuilles du circuit arithmétique sont λ et θ et les nœuds internes de l'arbre représentent une alternance de multiplications (*) ou d'additions (+). Il y a différentes façons de compiler une MLF en AC [12, 4].

Pour calculer la probabilité a posteriori pour le diagnostic : $P(x|e) = \frac{f(x,e)}{f(e)}$ (x une variable et e l'évidence), deux étapes sont nécessaires : la première pour évaluer $f(e)$, puis de calculer les dérivées de circuit pour obtenir $f(x,e) = \frac{\partial f}{\partial \lambda_x}$.

4.2. Atelier logiciel pour l'implémentation embarquée pour l'état de santé

L'implémentation HW/SW embarquée des modules "état de santé" se fait en deux phases (cf. figure 6) :

1. Hors-ligne : cette phase comprend l'analyse de type FMEA, la génération du réseau bayésien à partir de la table FMEA, la compilation du réseau bayésien en AC et la génération d'une description de bas niveau qui peut être exécutée sur un processeur général (CPU) ou un FPGA.
2. En-ligne : cette phase est exécutée en temps réel. Les valeurs de certains nœuds sont observées, ce qui permet de fixer les indicateurs d'évidence puis de calculer l'inférence. Une comparaison entre la version SW et HW est établie en terme de performance.




FIGURE 5 – a) Exemple d'un réseau bayésien et son MLF factorisée b) Le circuit arithmétique correspondant

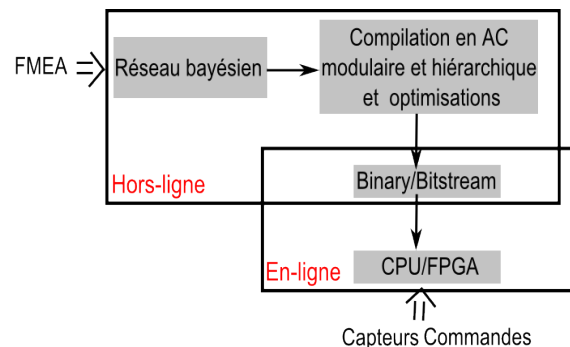


FIGURE 6 – Atelier logiciel pour l'implémentation embarquée pour l'état de santé

Les détails de ces deux phases sont abordés dans les travaux antérieurs [18, 17]. La nouveauté dans ce papier consiste à intégrer l'analyse de type FMEA et à la construction de l'AC d'une façon hiérarchique et modulaire par rapport au modèle proposé.

4.3. Approche de calcul d'inférence

La génération du composant HW/SW repose sur une nouvelle approche de calcul de l'inférence, utilisant la factorisation de la MLF et la structure régulière du modèle.

La factorisation de la MLF pour la construction de l'AC se base sur la relation entre les nœuds fils et leurs nœuds parents. Les sous-MLF des fils (si pas de dépendance conditionnelle entre les fils) sont représentées par un + dans l'AC et les parents les regroupent par des *. Dans notre modèle, tous les nœuds «erreur» et le nœud «moniteur de la tâche» sont des fils du nœud U (état inobservable du système). Il n'y a pas de dépendance conditionnelle entre ces nœuds, donc leurs MLF peuvent être calculées séparément et en parallèle. De même pour le sous réseau bayésien des erreurs où les fils sont les moniteurs (lui-même un sous réseau bayésien) et les contextes d'apparition. Cela nous permet de construire l'AC d'une manière hiérarchique et modulaire.

5. Expériences et résultats

Dans cette section, nous présentons les résultats de nos expériences. Nous illustrons notre approche en deux étapes, nous discutons d'abord l'évaluation de l'état de santé du GPS et de la consommation énergétique puis l'implémentation embarquée sur la ZedBoard.

5.1. Evaluation de l'état de santé

1. La figure 7 expose le cas "état de santé de la position donnée par le GPS". La figure 7.(a) montre l'état de santé avec des observations que sur les nœuds «capteur», dans le cas sans erreurs (de l'instant $t=0$ à $t=4$) et avec une erreur à l'instant $t=4$. La figure 7.(b) représente l'état de santé en rajoutant des observations sur les contextes d'apparition, qui renforce la croyance des capteurs et du coup de l'état de santé global du système.
2. La figure 8 expose le cas "état de santé de la consommation énergétique". En mettant entre $t=0$ et $t=4$ les évidences seulement sur les nœuds «capteur» ou «commande» (aucune perturbation), les résultats montrent un bon état de santé de la consommation énergétique qui diminue avec le temps car le réseau bayésien est dynamique. En rajoutant des observations sur les contextes d'apparition (aucune perturbation), cela renforce l'état de santé. A l'instant $t=4$, une erreur est injectée, les contextes d'apparition renforcent l'état de santé.




FIGURE 7 – Cas GPS sans (a) et avec (b) les évidences sur les contextes d'apparition

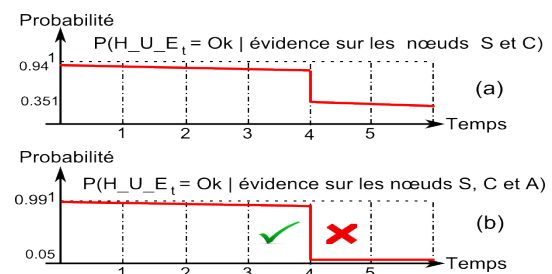


FIGURE 8 – Cas énergie sans (a) et avec (b) les évidences sur les contextes d'apparition

5.2. Implémentation embarquée sur la ZedBoard

L'implémentation HW/SW des états de santé est proposée sur un SoC hybride (Zedboard de Xilinx), avec une architecture comprenant un processeur Zynq ARM Cortex-A9 et une partie FPGA. Cette architecture permet une mise en œuvre pour une implémentation complètement HW, complètement SW, ou mixte. Dans notre étude, nous développons des implémentations HW/SW pour avoir la possibilité de choisir l'implémentation la plus adéquate selon le besoin et la charge du CPU.

La table 2 et la table 3 donnent un aperçu sur les ressources matérielles et les temps d'exécution HW et SW. Ainsi, un choix sur l'implémentation peut être adapté selon les performances exigées et les ressources disponibles.

La table 2 donne l'évaluation hors-ligne des ressources pour le calcul de l'état de santé associé au GPS et à la consommation énergétique en termes de Bloc RAM (mémoire BRAM), processeurs de signal numérique (DSP), table de correspondance (LUT) et registres Flip Flop (FF). Le nombre total de DSP sur le ZedBoard est égal à 220, celui de LUT 53200 et celui de FF 106400. Le nombre de ressources pour l'implémentation HW peut être réduit en utilisant des optimisations basées sur la connaissance que nous possédons des noeuds observables (noeuds S et C), non observables (U et H) et des noeuds contexte d'apparition A (qui peuvent être observables ou non). Les résultats sont donnés pour des solutions matérielles maximisant le parallélisme. Les résultats pour les ressources montrent que le réseau du GPS consomme plus de DSP que le réseau de l'énergie car il explore plus le parallélisme. La construction de l'AC et les sous-calculs des sous réseaux (types d'erreur) dans le cas du GPS peuvent se faire de manières indépendantes et parallèles. Les optimisations basées sur les évidences, diminuent le nombre de LUT et FF plus dans le réseau de l'énergie que dans le réseau du GPS. Moins les noeuds contextes d'apparition sont présents, plus les optimisations utilisant les évidences sont efficaces.

	BRAM	DSP	LUT	FF
GPS sans opt.	0%	36%	36 %	10%
GPS avec opt.	0%	36%	33%	9%
Energie sans opt.	0%	29 %	40%	11%
Energie avec opt.	0%	29%	27%	7%

TABLE 2 – Ressources utilisées sur la partie logique programmable

	temps HW (cycles)	temps SW (cycles)	Acc1	Acc2
GPS sans opt.	401	1123	4.30	2.80
GPS avec opt.	391	955	3.80	2.42
Energie sans opt.	412	1488	5.47	3.61
Energie avec opt.	339	1268	6.22	3.74

TABLE 3 – Performances de l'implémentation embarquée

La table 3 montre les performances en-ligne du calcul de l'état de santé associé au GPS et à la consommation énergétique. Les résultats pour les performances montrent que l'implémentation HW est plus performante que l'implémentation SW dans tous les cas. Acc2 représente l'accélération observée avec un stockage externe des paramètres du réseau, ce qui génère des temps de communication assez importants. Cela peut être réduit avec un stockage interne des paramètres, ce qui est représenté par Acc1. Comme le parallélisme peut être plus exploité dans le cas de l'état de santé associé au GPS, un meilleur temps HW est observé pour le cas du GPS, alors que ces deux réseaux (GPS et energie) comprennent le même nombre de noeuds. De même pour le temps SW, car l'algorithme dans le cas de l'énergie est plus complexe en termes de branches de calcul, dû aux dépendances entre les noeuds. Tout cela donne une meilleure accélération dans le cas de l'énergie mais un meilleur temps SW et HW dans le cas du GPS. Pour les optimisations, elles sont plus efficaces en termes de performance dans le cas de l'énergie, qui est dû au nombre moins important des noeuds contextes d'apparition.

6. Conclusion

Dans cet article, nous avons présenté un modèle d'évaluation de l'état de santé pour les systèmes autonomes. Notre approche est basée sur l'analyse des modes de défaillances, leurs effets et leurs contextes d'apparition en utilisant des réseaux bayésiens. Nous avons également présenté un atelier logiciel pour générer des implémentations matérielles et logicielles sur Zed-board incorporant un dispositif hybride (Zynq SoC). On peut constater des limitations à notre approche, qui sont le besoin d'un grand nombre de capteurs et la complexité de l'implémentation qui dépend du nombre des types d'erreurs. Cette dernière limitation peut être remédiée par le compromis entre le partage des ressources et les performances.

Le composant de santé est une brique de base pour aider à la prise de décision lors d'une mission. Son implémentation sur FPGA permet d'envisager une reconfiguration dynamique en ligne sur le système embarqué.

Bibliographie

1. Automotive Industry Action Group (A.). – *Potential Failure Mode and Effects Analysis (FMEA) : Reference Manual*. – Chrysler Corporation, 1993.
2. Becker (A.) et Naïm (P.). – *Les réseaux bayésiens : modèles graphiques de connaissance*. – Paris, Eyrolles, 1999.
3. Bottone (S.), Lee (D.), O'Sullivan (M.) et Spivack (M.). – Failure prediction and diagnosis for satellite monitoring systems using Bayesian networks. – In *Military Communications Conference. MILCOM 2008. IEEE*, pp. 1–7, Nov 2008.
4. Chavira (M.) et Darwiche (A.). – Compiling Bayesian networks using variable elimination. – In Veloso (M. M.) (édité par), *IJCAI*, pp. 2443–2449, 2007.
5. Cowell (R. G.). – *Probabilistic networks and expert systems : Exact computational methods for Bayesian networks*. – Springer Science & Business, 2006.
6. Darwiche (A.). – A differential approach to inference in Bayesian networks. *J. ACM*, vol. 50, n3, 2003, pp. 280–305.
7. Darwiche (P. A.). – *Modeling and reasoning with Bayesian networks*. – New York, NY, USA, Cambridge University Press, 2009, 1st édition.
8. Drevelle (V.) et Bonnifait (P.). – Reliable positioning domain computation for urban navigation. *Intelligent Transportation Systems Magazine, IEEE*, vol. 5, n3, 2013, pp. 21–29.
9. Huang (C.) et Darwiche (A.). – Inference in belief networks : A procedural guide. *International Journal of Approximate Reasoning*, vol. 15, 1996, pp. 225–263.
10. Kulesza (Z.) et Tylman (W.). – Implementation of Bayesian network in fpga circuit. – In *Proceedings of the International Conference on Mixed Design of Integrated Circuits and System*, pp. 711–715, June 2006.
11. Langley (R. B.). – The gps error budget. *GPS world*, vol. 8, n3, 1997, pp. 51–56.
12. Lian (Z.), Jinsong (Y.), Jiuqin (W.) et Wei (X.). – Real time diagnosis with compiling Bayesian networks. – In *6th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, pp. 542–546, June 2011.
13. Liu (Z.) et Mrad (N.). – Validation of strain gauges for structural health monitoring with Bayesian belief networks. *Sensors Journal, IEEE*, vol. 13, n1, Jan 2013, pp. 400–407.
14. Pearl (J.). – *Probabilistic reasoning in intelligent systems : Networks of plausible inference*. – San Francisco, CA, USA, Morgan Kaufmann Publishers Inc., 1988.
15. Schumann (J.), Mbaya (T.), Mengshoel (O.), Pipatsrisawat (K.), Srivastava (A.), Choi (A.) et Darwiche (A.). – Software health management with bayesian networks. *Innovations in Systems and Software Engineering*, vol. 9, n 4, 2013, pp. 271–292.
16. Schumann (J.), Moosbrugger (P.) et Rozier (K. Y.). – R2u2 : Monitoring and diagnosis of security threats for unmanned aerial systems. – In *Runtime Verification*, pp. 233–249. Springer, 2015.
17. Zermani (S.), Dezan (C.), Chenini (H.), Diguët (J.-P.) et Euler (R.). – FPGA implementation of bayesian network inference for an embedded diagnosis. – In *Prognostics and Health Management (PHM), 2015 IEEE Conference on*, June 2015.
18. Zermani (S.), Dezan (C.), Euler (R.) et Diguët (J.-P.). – Bayesian network-based framework for the design of reconfigurable health management monitors. – In *Adaptive Hardware and Systems (AHS), 2015 NASA/ESA Conference on*, June 2015.
19. Zheng (L.), Mengshoel (O. J.) et Chong (J.). – Belief propagation by message passing in junction trees : Computing each message faster using gpu parallelization. *CoRR*, vol. abs/1202.3777, 2012.