



HAL
open science

L'intelligence artificielle au service de la maintenance prévisionnelle

Juliette Mattioli, Pierre-Olivier Robic, Thomas Reydelle

► **To cite this version:**

Juliette Mattioli, Pierre-Olivier Robic, Thomas Reydelle. L'intelligence artificielle au service de la maintenance prévisionnelle. 4ème conférence sur les Applications Pratiques de l'Intelligence Artificielle APIA2018, Jul 2018, Nancy, France. hal-01830917

HAL Id: hal-01830917

<https://hal.science/hal-01830917>

Submitted on 5 Jul 2018

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

L'intelligence artificielle au service de la maintenance prévisionnelle

Juliette MATTIOLI¹

Pierre-Olivier ROBIC²

Thomas REYDELLET¹

¹ Thales Research & Technology, Campus Polytechnique 1 av. A. Fresnel, 91767 Palaiseau Cedex

² Thales Global Services, 19 av. M. Saulnier, 78140 Vélizy Villacoublay.

{juliette.mattioli, pierre-olivier.robic, thomas.reydellet}@thalesgroup.com

Résumé

Avec la transformation numérique du Groupe Thales, l'intelligence artificielle (IA) qu'elle soit orientée par les modèles (IA symbolique) ou basée sur les données (IA connexioniste) devient un élément clé pour la maintenance prévisionnelle. L'objectif de cet article est de dresser un rapide panorama des différentes technologies d'IA mise en oeuvre dans Thales pour outiller les activités de maintenance prévisionnelle.

Mots Clef

Maintenance prévisionnelle, IA symbolique, IA connexioniste, diagnostic, pronostic, planification, ordonnancement.

Abstract

With the Thales Group digital transformation, model-driven AI (Artificial Intelligence) and data-driven AI are becoming a cornerstone to predictive maintenance. The aim of this paper is to give a brief overview of various AI techniques which are used to address predictive maintenance issues.

Keywords

Predictive maintenance, Symbolic AI, Connectionist AI, diagnostic, prognostic, planning, scheduling.

1 Maintenance prévisionnelle : un levier de compétitivité

Selon la définition de l'AFNOR [1], la maintenance couvre l'ensemble de toutes les actions durant le cycle de vie d'un système, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise. Les activités induites sont aujourd'hui de deux types : corrective ou préventive. La maintenance corrective est programmée suite à une défaillance¹. Cependant, ces activités n'intègrent pas d'aspect préventif. Fondée sur l'adage "*mieux vaut prévenir que guérir*", la maintenance préventive repose sur un plan déterminé a priori. La fréquence des ces opérations s'appuie en général sur des options de garantie,

des instructions du fournisseur, la réglementation ou l'expérience. Mais elle intervient parfois trop tard et provoque une augmentation des activités de maintenance corrective, et cela parce que les conditions réelles et les usages ne sont pas pris en compte.

Avec la transformation numérique du Groupe Thales, une nouvelle forme de maintenance devient possible grâce aux technologies de l'intelligence artificielle (IA) : la maintenance prévisionnelle [2]. Cette dernière est réalisée suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de dégradation du système. Ce type de maintenance vise à prédire l'évolution de ces paramètres pour estimer le temps de fonctionnement restant avant défaillance (pronostic). Cette approche est souvent qualifiée de maintenance prédictive, car reposant sur les évolutions de paramètres surveillés dans le futur, et de maintenance proactive qui cherche à déterminer les causes à l'origine de ces dégradations et de ces défaillances.

Thales propose ainsi une offre complète de maintenance pour les systèmes critiques, offre de services outillée allant de la réparation et la fourniture de pièces de rechange à la maintenance prévisionnelle, préventive et corrective. En effet, tout système en fonctionnement qu'il soit critique ou non, manifeste des signes, visibles ou non, de dégradation annonçant une future défaillance. La détection d'anomalies ou de changements préfigurent alors à court terme d'une panne à venir. C'est pourquoi, comme nous le verrons dans la suite de ce papier, Thales propose des solutions innovantes reposant sur des approches à base d'IA, pour chacune des étapes de maintenance. En effet, l'IA que nous définissons comme "*des systèmes d'information et des applications pouvant percevoir un environnement, comprendre et décider en fonction du contexte et des usages, tout en apprenant au fil de l'eau*", qu'elle soit dirigée par les données (IA connexioniste) ou basée sur des modèles et la connaissance (IA symbolique) est devenue pour Thales, incontournable pour la surveillance de l'état de santé du système, la planification et la gestion des opérations de maintenance.

2 Diagnostic

L'idée de la maintenance prévisionnelle est de projeter l'état actuel d'un système dans le futur, afin d'en estimer sa

1. Une défaillance correspond à une cessation de l'aptitude d'une entité à accomplir une ou plusieurs fonctions requises.

durée de vie restante (i.e., durée de fonctionnement avant défaillance) appelée communément RUL (remaining useful life), ou de calculer sa probabilité pour qu'il fonctionne durant un certain temps ainsi que le risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance. Plusieurs techniques d'IA permettent de diagnostiquer les fautes survenant dans un système qui provoquent des défaillances.

Certaines reposent sur la connaissance disponible du fonctionnement normal (comportement nominal) ou anormal (comportement en présence de faute) du système [3] pour établir des relations causales entre les causes et les effets observés ou les symptômes, les défaillances et les fautes. Ces méthodes exploitent la connaissance des experts sur le système, une connaissance acquise durant les opérations de maintenance ou/et d'un historique des dysfonctionnements du système. Elles peuvent être capturées par le biais par exemple d'ontologies [4] et/ou se basent sur l'existence d'un modèle formel du système qui impliquent une connaissance approfondie de son fonctionnement sous la forme de modèle mathématique et/ou logique. Ainsi pour certains systèmes critiques, Thales a mis en oeuvre des méthodes de diagnostic de défaillances [5] modélisations fonctionnelles et matérielles reposant sur des outils industriels comme l'AMDEC (Analyse des Modes de Défaillance, de leur Effet et de leur Criticité) des arbres de défaillances ou par le biais de modélisation physique consistant à comparer un modèle représentatif du bon fonctionnement du système avec les mesures observées [6]. Tout écart est alors synonyme d'un dysfonctionnement, c'est-à-dire la présence d'un ou plusieurs défauts. A partir de ces études, Thales a développé des **systèmes d'inférence** pour l'aide au diagnostic.

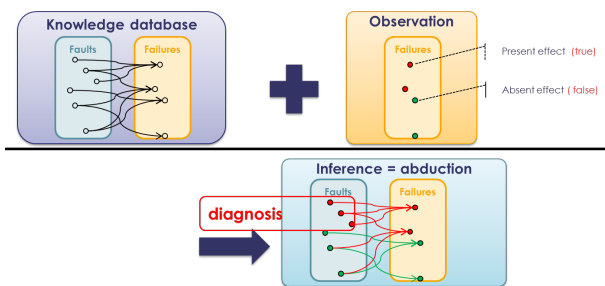


FIGURE 1 – Principe de raisonnement abductif pour l'aide au diagnostic

La propriété principale de cette approche est de pouvoir représenter et restituer les connaissances acquises par les experts. Rappelons qu'un tel système comporte une base de connaissances composée d'une base de règles qui modélise la connaissance et d'une base de faits qui contient les informations concernant le système observé et un moteur d'inférence capable de raisonner à partir des informations contenues dans la base de connaissances et de faire des déductions.

Quand cette connaissance n'est pas accessible, d'autres approches consistent à traiter le système comme étant une boîte noire. Les mesures (entrées-sorties) constituent souvent la plus forte et la plus sûre source d'informations pour comprendre les phénomènes de dégradation. L'objectif est d'associer ces observations à des états de fonctionnement connus du système. Ces approches à base d'IA basées sur les données, visent à apprendre (par les exemples) le phénomène de dégradation et à capturer les relations subtiles entre données, même si ces relations sont inconnues ou difficiles à décrire. Ainsi, Thales propose une combinaison d'approches [7] combinant des approches statistiques, l'**analyse en composante principale** pour identifier les interactions entre les différents composants du système et réduire la complexité, les **chaînes de Markov cachées** pour retrouver l'ensemble des états les plus probables à partir d'une séquence de sortie, les **réseaux bayésiens** pour permettre la corrélation d'événements et la détection de signaux faibles, les **arbres de décision** ou **réseaux de neurones** comme le **deep learning**. Ces approches exploitent les données de surveillance (issues de capteurs) ou d'interventions de maintenance, données traitées afin d'extraire des caractéristiques reflétant le comportement du système et sa dégradation. Celles-ci sont ensuite utilisées pour apprendre des modèles de prédiction des états du système, et calculer une estimation du RUL.

3 Prognostic

Le diagnostic traite de l'identification et de la quantification des dommages qui se sont produits, alors que le pronostic porte sur la prédiction non seulement des possibles états futurs dans lesquels un système peut évoluer mais aussi des dommages qui n'ont pas encore eu lieu. Sa fonction principale est de renforcer le choix des actions à entreprendre pour proposer des recommandations pour l'ordonancement des tâches de maintenance. Il permet d'aborder la maintenance prévisionnelle tout en réduisant ses coûts directs. Les méthodes pour le pronostic dépendent comme celles pour le diagnostic, de la connaissance et des données que l'on a sur le système à maintenir. Elles sont soit fondées sur un modèle physique, soit guidées par les données, soit basées sur l'expérience. Cette dernière s'appuie principalement sur des approches fiabilistes, sur des modélisations de processus stochastiques ou sur des systèmes experts.

Les approches à base de modèles, développées dans Thales, consistent à simuler le modèle de comportement du système pour caractériser la dynamique des paramètres reflétant la dégradation. Par exemple, le suivi de la dégradation et l'obtention de sa dynamique peuvent être modélisé par un filtre de Kalman, par un filtrage particulaire ou par des chaînes de Markov cachées [3].

Les méthodes guidées par les données sont, avec le renouveau de l'IA, en pléines expansions. Elles exploitent des mesures représentant l'état actuel et/ou l'état passé. Elles utilisent des techniques d'**apprentissage** ou des techniques

d'**analyse de tendance** pour construire un modèle à partir de ces données pour ensuite extrapoler l'évolution du système. Cependant, elles supposent que la probabilité d'évolution est proche des conditions de fonctionnement utilisées lors de l'apprentissage du modèle. Les **réseaux de neurones adaptatifs**, les **machines à vecteurs de support** sont des approches qui ont révélées leur efficacité pour la prévision de séries temporelles. Leur intérêt réside dans leurs aptitudes à apprendre et à capturer les relations potentielles entre les données même si le comportement est complexe. Ces modèles sont appris par un ensemble d'échantillons (entrées/sorties) directement extrait de la séquence d'observations. Enfin, la **fusion d'informations** [8] permet la corrélation d'un indicateur de santé avec les conditions opératoires permet de déterminer un RUL en considérant à la fois l'état de santé courant du système et son utilisation. Cependant, ces approches sont difficiles à mettre en oeuvre pour les équipements complexes, leur réponse est souvent entachée d'incertitudes de modélisation ce qui induit un pronostic moins robuste. Pour avoir un modèle robuste permettant de prendre en compte les imperfections et les incertitudes, la **logique floue** et les **fonctions de croyances** sont très utilisées [9]. Combinée avec les méthodes citées ci-dessus, elles offrent un compromis raisonnable entre les modèles analytiques rigoureux, les approches reposant sur des connaissances métier et les approches guidées par les données.

4 Planification et Ordonnancement

Dans toute opération de maintenance préventive, il s'agit d'établir un planning prévisionnel des tâches sous-jacentes incluant les ressources humaines et matérielles impliquées. Ainsi, les dates de début au plus tôt, les durées et les dépendances des tâches sont connues a priori. Concernant les tâches de maintenance corrective, leur durée est basée sur une estimation et dépend d'un bon diagnostic. Or, un tel planning est généralement figé et peu ouvert aux changements et donc à des actions correctives qui sont par essence non planifiées.

Pour construire un tel ordonnancement mixant maintenance préventive et corrective, Thales utilise une combinaison de la **programmation par contraintes** avec des approches multicritères [10, 11] pour affecter des tâches aux opérateurs sous contrainte de compétence, en minimisant la date de fin de l'ordonnancement et les pénalités de retards [2]. Une approche outillée d'aide à la **décision multicritère** [12] a été mise en place (cf. figure 2), en particulier pour modéliser par le biais d'une fonction multicritère intégrant des dimensions de natures variées comme les arrêts de production, le retard dans l'exécution des tâches, les pénalités et d'autre part, des coûts de maintenance acceptables. De plus, avec la maintenance prévisionnelle, un réordonnancement est à envisager, en tenant compte du RUL. L'évolution du planning devient alors dynamique suite aux dysfonctionnements du système de production [13]. Enfin, la prise en compte de la maintenance dès la conception per-

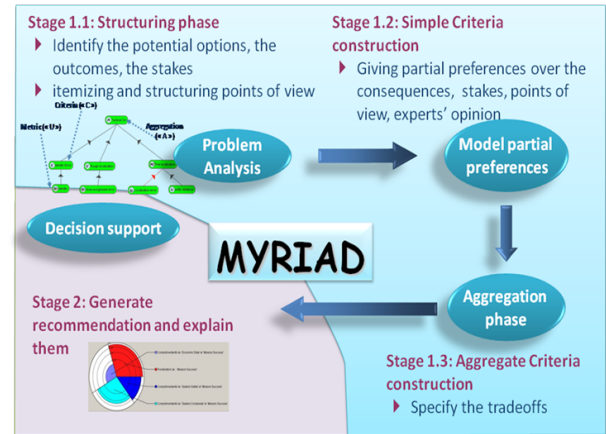


FIGURE 2 – Méthodologie Myriad développée par Thales pour construire une fonction multicritère

met de concevoir des outils d'aide à la décision pour une optimisation de la gestion du système en mode dégradé comme le montre [5].

5 Conclusion

Une politique de maintenance prévisionnelle efficace doit conduire à une réduction des pertes engendrées par des indisponibilités de production. Son efficacité est fortement liée à sa faculté de caractériser l'état de santé courant (diagnostic) et futur (pronostic) du système. Pour cela, il est nécessaire de pouvoir générer des données permettant de rendre compte de la dynamique de la dégradation du système, de modéliser ou d'apprendre ses modes de dégradation, d'estimer son état de santé et de prédire sa durée de vie résiduelle. Les techniques d'IA qu'elles soient symboliques ou connexionnistes deviennent incontournables pour les activités de maintenance de Thales. Cependant, comme le montre la figure 3, il s'agit d'une combinaison d'approches qui dépendent de la connaissance disponible du fonctionnement nominal et du type de fautes mais aussi des données d'observation de l'état de santé du système.

Références

- [1] Norme AFNOR. Terminologie de la maintenance. *NF-EN, 13306 :X60-319*, 2001.
- [2] Simon Fossier and Pierre-Olivier Robic. Maintenance of complex systems : From preventive to predictive. In *Live Maintenance (ICOLIM), 2017 12th International Conference on*, pages 1–6. IEEE, 2017.
- [3] Camille Baysse. *Analyse et optimisation de la fiabilité d'un équipement opto-électrique équipé de HUMS*. PhD thesis, Université Sciences et Technologies-Bordeaux I, 2013.
- [4] Luis Palacios, Gaëlle Lortal, Claire Laudy, Christian Sannino, Ludovic Simon, Giuseppe Fusco, Yue Ma, and Chantal Reynaud. Avionics maintenance ontology building for failure diagnosis support. In *Procee-*




FIGURE 3 – Exemple d’approches mises en oeuvre dans Thales pour la maintenance

dings of the International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management, pages 204–209. SCITEPRESS-Science and Technology Publications, Lda, 2016.

- [5] J. Sprauel, C. Sannino, and C. Seguin. Techniques d’aide à la décision appliquées à la maintenance d’un avion de type business jet decision aiding techniques applied to the maintenance of a business jet. In *Congrès Lambda Mu 19*, 2014.
- [6] Camille Baysse, Didier Bihannic, Anne Gégout-Petit, Michel Prenat, and Jérôme Saracco. Hidden markov model for the detection of a degraded operating mode of optronic equipment. *arXiv preprint arXiv :1212.2358*, 2012.
- [7] Michel Giraudeau, Emilie Ronfaut, and D Bihannic. Apport des hums sur les performances sdf et soutien des équipements électroniques embarqués. *7A-Maintenance-diagnostic/pronostic*, 2014.
- [8] Claire Laudy and Jean-Gabriel Ganascia. Introducing semantic knowledge in high-level fusion. In *Military Communications Conference, 2009. MILCOM 2009. IEEE*, pages 1–7. IEEE, 2009.
- [9] Simon Fossier, Claire Laudy, and Frédéric Pichon. Managing uncertainty in conceptual graph-based soft information fusion. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 930–937. IEEE, 2013.
- [10] Fabien Le Huédé, Michel Grabisch, Christophe Labreuche, and Pierre Savéant. Integration and propagation of a multi-criteria decision making model in constraint programming. *Journal of Heuristics*, 12(4-5) :329–346, 2006.
- [11] Fabien Le Huédé, Michel Grabisch, Christophe Labreuche, and Pierre Savéant. Mcs : A new algorithm

for multicriteria optimisation in constraint programming. *Annals of Operations Research*, 147(1) :143–174, 2006.

- [12] Michel Grabisch and Christophe Labreuche. A decade of application of the choquet and sugeno integrals in multi-criteria decision aid. *Annals of Operations Research*, 175(1) :247–286, 2010.
- [13] Christian Sannino, Jonathan Sprauel, and Christel Seguin. Modèles dysfonctionnels pour la gestion de la qualité de service des systèmes critiques. *3R-Recherche et Industrie 1*, 2016.