

Une IA hybride pour la surveillance de la santé du système de lubrification et de refroidissement de la BTP d'un hélicoptère

Ammar Mechouche, Matthis Houles, Jérôme Belmonte et Pierre-Loic Maisonneuve

Airbus Helicopters, 13700 Marignane, France

Ammar.Mechouche@Airbus.com

Résumé

Ce résumé présente une approche combinant l'apprentissage automatique et l'intelligence artificielle symbolique pour la surveillance du système de lubrification et de refroidissement de la boîte de transmission principale (BTP) d'un hélicoptère. Les modèles d'apprentissage automatique détectent les anomalies, tandis que l'IA symbolique intervient pour en diagnostiquer l'origine ou les invalider à l'aide de règles floues définies par des experts métier. Les résultats obtenus sont prometteurs et ouvrent la voie à un déploiement de la solution dans Flyscan, un service de maintenance prédictive proposé aux clients d'Airbus Helicopters.

Mots-clés

IA hybride, surveillance santé, hélicoptère.

Abstract

In this abstract we present an approach combining machine learning and symbolic artificial intelligence for monitoring the lubrication and cooling system of a helicopter's main gearbox (MGB). Machine learning models detect anomalies, while symbolic AI diagnoses their origin or invalidates them using fuzzy rules defined by domain experts. The results are promising and pave the way for deploying the solution in Flyscan, a predictive maintenance service offered to Airbus Helicopters customers.

Keywords

Hybrid AI, health monitoring, helicopter.

1 Introduction

La surveillance de l'état de santé des systèmes dynamiques des hélicoptères est un enjeu majeur pour améliorer la sécurité des vols, optimiser la disponibilité des appareils et réduire les coûts de maintenance. Traditionnellement, cette surveillance repose sur l'analyse des signaux vibratoires captés au plus près des composants mécaniques. Bien que ces techniques de traitement du signal soient éprouvées et offrent des résultats fiables, elles ne permettent pas de couvrir l'ensemble des systèmes critiques. Pour pallier cette limitation, d'autres sources de données, collectées en vol via le système HUMS (Health & Usage Monitoring System), peuvent être exploitées afin d'enrichir et

d'améliorer la surveillance.

Dans ce résumé, nous proposons une approche combinant l'apprentissage automatique et l'intelligence artificielle symbolique pour surveiller le système de refroidissement et de lubrification de la BTP d'un hélicoptère. Cette solution, détaillée en section 3, vise à améliorer la détection précoce d'anomalies et à renforcer la maintenance prédictive.

Les résultats obtenus sont prometteurs et ouvrent la voie à un déploiement dans Flyscan, le service de maintenance prédictive d'Airbus Helicopters. Une version détaillée de ce système de surveillance a été présentée à l'European Rotorcraft Forum 2023 [1] et s'inscrit dans la continuité des travaux publiés dans [2]. L'originalité de cette approche réside dans l'association de modèles de normalité construits par apprentissage automatique, de règles de détection établies par les experts métiers et de la logique floue pour le suivi de l'état de santé d'un système complexe.

2 Description de la méthode

Le système de lubrification et de refroidissement joue un rôle essentiel dans le bon fonctionnement de la BTP (Figure 1). Il est composé de deux circuits pressurisés, principal et secondaire, permettant d'assurer la lubrification des pièces en contact pour la transmission de puissance, l'évacuation de la chaleur générée via le radiateur, ainsi que l'élimination des polluants au niveau du filtre à huile. La solution développée exploite les capteurs de pression et de température d'huile situés à différents endroits du système (éléments 1, 2, 3, 6 et 7 sur la Figure 1).

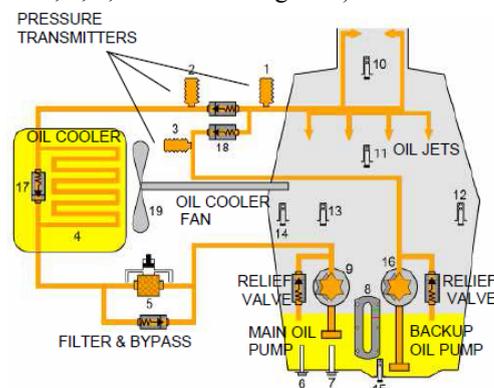


Figure 1 : Système de lubrification et de refroidissement de la BTP d'un hélicoptère.

La solution développée repose sur deux étapes principales.

2.1 Détection des anomalies

La première étape consiste à construire des modèles de normalité grâce à des algorithmes d'apprentissage automatique (Forêt d'arbres aléatoires) exploitant les vastes quantités de données de vol collectées (de l'ordre de dizaines de milliers d'heures de vol). Pour garantir la robustesse des modèles, les vols présentant des anomalies avérées ont été exclus de la base d'apprentissage. De plus, certaines règles métier ont été appliquées afin de limiter l'apprentissage aux phases de vol thermiquement stables, propices à l'estimation de valeurs de normalité.

Après chaque vol client – et uniquement durant ces phases spécifiques – les valeurs nominales des capteurs de pression et de température d'huile sont estimées à partir d'un ensemble de paramètres de vol collectés par le Flight Data Continuous Recorder (FDCR) (altitude, vitesse, puissance motrice, température extérieure, etc. - rectangles bleus en haut de la Figure 2). Ces valeurs inférées sont ensuite comparées aux mesures réelles des capteurs physiques. Trois situations peuvent alors être identifiées : les mesures sont conformes aux prédictions ; les mesures sont significativement supérieures ou inférieures aux valeurs attendues : les paramètres sont jugés anormalement élevés ou anormalement bas, respectivement. Afin de gérer les incertitudes, un formalisme de logique floue est employé. Chaque paramètre de pression et de température se voit ainsi attribuer un score de normalité compris entre 0 et 1, reflétant son état (normal, anormalement élevé ou anormalement bas). Cette première étape permet ainsi de détecter les anomalies dans le système.

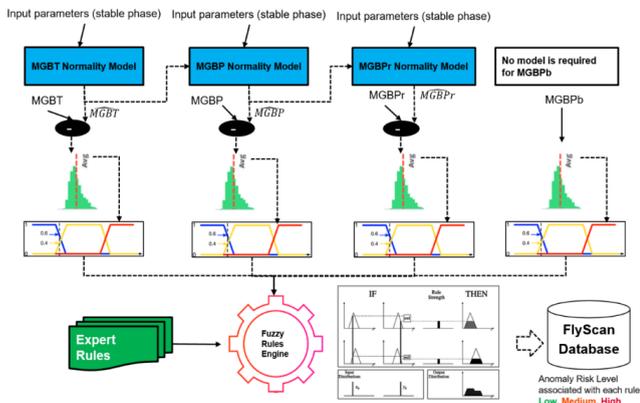


Figure 2 : Vue globale de la solution développée pour la surveillance du système.

2.2 Diagnostic des anomalies

La seconde étape vise à déterminer l'origine de l'anomalie détectée ou, le cas échéant, à invalider une alerte erronée issue des modèles d'apprentissage automatique. Pour ce faire, un ensemble de règles de diagnostic, définies par les experts métier, est appliqué. Ces règles permettent d'identifier avec précision le mode de panne en question ainsi que le sous-système concerné, en s'appuyant sur l'état de normalité de chaque paramètre évalué lors de l'étape précédente. Par exemple, l'une de ces règles s'énonce comme suit : **SI** la pression d'huile principale (capteur 2)

est anormalement élevée **ET** la pression de secours (capteur 3) est normale **ET** la pression à la rampe (capteur 1) est anormalement élevée **ET** la température d'huile au fond de la boîte (capteur 6) est normale, **ALORS** l'anomalie est due au colmatage des gicleurs d'huile. Une douzaine de modes de panne du système sont ainsi surveillés grâce à ces règles, qui sont exécutées par un moteur d'inférence flou. Ce dernier attribue à chaque diagnostic un niveau de criticité (bas, moyen ou élevé). Le support HUMS vérifie ces diagnostics et décide d'alerter ou non le client.

3 Résultats

Le système décrit est implémenté et testé sur des données réelles. La Table 1 décrit les résultats d'évaluation, plutôt satisfaisants, des modèles de normalité de la pression principale (MGBP), température principale (MGBT) et la pression à la rampe (MGBPp). La normalité de la pression de secours étant simple à gérer sans modèle de normalité.

Model / Metrics	R2 (%)	RMSE
MGBP	74.4	0.27 (bar)
MGBT	85.1	3.89 (°C)
MGBPp	96.0	0.10 (bar)

Table 1 : Résultats de l'évaluation du système.

La solution dans la globalité, incluant les règles de l'expert, a été testée sur des données réservées pour le test et comprenant un historique de plusieurs milliers de vols d'hélicoptères pour lesquels, par ailleurs, les données de maintenance, d'incidents et de révisions étaient disponibles. Ainsi, pour chaque anomalie détectée par le système, il est vérifié si, aux alentours de la date d'occurrence de l'anomalie, une action de maintenance a été effectuée par le client sur le système, ou si un incident incriminant le système a été enregistré ou si une dégradation a été constatée sur le système lors de sa révision. Sur **14** hélicoptères et **62000** heures de vol, le système a pu détecter l'anomalie dans **7** cas sur **9**, un cas ambigu et seulement un cas non détecté.

4 Suite des travaux

La suite des travaux se focalise d'une part sur l'amélioration des modèles de normalité par l'utilisation de nouveaux algorithmes d'IA. D'autre part, ces travaux abordent les aspects de confiance dans les modèles d'IA auprès des professionnels du support HUMS.

5 Références

- [1] Mechouche A., Houles M., Belmonte J., Maisonneuve P.-L., "Monitoring of MGB Lubrication and Cooling System based on Big Data Normality Models and Fuzzy Expert Rules", European Rotorcraft Forum, 2023.
- [2] Daouayry N., Mechouche A., Maisonneuve P.L., Scuturici V.M., Petit J.M., "Data-centric helicopter failure anticipation: The MGB oil pressure virtual sensor case", IEEE International Conference on Big Data, 2019.