



الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث
العلمي

Ministère de l'Enseignement Supérieure et de la Recherche Scientifique

جامعة وهران 2 محمد بن أحمد

Université d'Oran 2 Mohamed Ben Ahmed

معهد الصيانة و الأمن الصناعي

Institut de Maintenance et de Sécurité Industrielle

Département de Maintenance en Instrumentation

MÉMOIRE

Pour l'obtention du diplôme de Master

Filière : Génie Industriel

Spécialité : Ingénierie de Maintenance en Instrumentation

Thème

**Sélection automatique des données de capteur en vue du
PHM**

Présenté et soutenu publiquement par :

Dahnoun Djefal

Yacine

Amarouchi

Mohammed el Amine

Devant le jury composé de :

Nom et Prénom	Grade	Etablissement	Qualité
YAHIAOUI Reda	MCA	Université d'Oran 2	Président
NOUREDDINE Rachid	professeur	Université d'Oran 2	Encadreur
MOTRANI Asmaa	Docteur	Université d'Oran 2	Co-encadreur
BOUCHAALA Abdelghani	MAB	Université d'Oran 2	Examineur

2022/2023

Résumé :

La maintenance prédictive est basée sur la prédiction future des défaillances. Elle est une approche visant à assurer la sûreté de fonctionnement et les performances globales des systèmes industriels, tout en réduisant les coûts de cycle de vie. Le pronostic industriel a pour objectif de prédire l'état futur du système surveillé, en estimant notamment sa durée de vie utile restante (RUL). Parmi les différentes approches, le pronostic guidé par les données qui traite les données hétérogènes et améliore la disponibilité, la fiabilité et la sécurité des systèmes industriels. L'objectif de ce travail est de classifier les données des capteurs de la base C-MAPPS en utilisant MATLAB afin de contribuer à la mise en œuvre de la méthodologie PHM (Prognostics and Health Management). Le programme réalisé génère une matrice de sélection des capteurs significatifs de la dégradation de turboréacteurs. Les résultats obtenus présentent un potentiel prometteur pour l'amélioration des prédictions dans le cadre de la maintenance prédictive et PHM.

Abstract:

Predictive maintenance is based on the future prediction of failures. It is an approach aimed at ensuring the operational safety and overall performance of industrial systems while reducing life cycle costs. Industrial prognosis aims to predict the future state of the monitored system, including estimating its remaining useful life (RUL). Among the various approaches, data-driven prognosis deals with heterogeneous data and improves the availability, reliability, and security of industrial systems. The objective of this work is to classify sensor data from the C-MAPPS database using MATLAB to contribute to the implementation of PHM (Prognostics and Health Management) methodology. The implemented program generates a matrix for selecting significant sensors for the degradation of turbofan engines. The obtained results show promising potential for improving predictions in the context of predictive maintenance and PHM.

المخلص:

الصيانة التنبؤية تستند إلى توقع الأعطال المستقبلية. إنها نهج يهدف إلى ضمان سلامة التشغيل والأداء الشامل للأنظمة الصناعية، مع الحد من تكاليف دورة الحياة. يهدف التنبؤ الصناعي إلى توقع الحالة المستقبلية للنظام المراقب، بما في ذلك تقدير فترة الحياة المفيدة المتبقية (RUL). من بين النهج المختلفة، هناك تنبؤ يستند إلى البيانات التي تعامل مع البيانات المتنوعة وتعزز التوفر والموثوقية والأمان للأنظمة الصناعية. هدف هذا العمل هو تصنيف بيانات المستشعرات من قاعدة بيانات C-MAPPS باستخدام MATLAB للمساهمة في تنفيذ منهجية PHM (التنبؤ وإدارة الصحة). يقوم البرنامج المنفذ بتوليد مصفوفة لتحديد المستشعرات الهامة لتدهور محركات التوربين. تُظهر النتائج المحصل عليها إمكانات واعدة لتحسين التوقعات في سياق الصيانة التنبؤية و PHM.

Remerciements

On remercie Allah le tout puissant, le tout miséricordieux. Au terme de ce modeste travail, nous tenons à exprimer nos remerciements les plus chaleureux à tous les membres de nos familles, à nos chers amis qui nous ont donné le courage et la sérénité. A nos chers professeurs de l'institut de maintenance et de sécurité industrielle, qui nous ont instruit en transmettant leur savoir et qui nous a permis de réaliser ce projet. On remercie particulièrement nos chers encadreurs **Pr. Nouredine Rachid et Dr. Motrani Asmaa** pour son dévouement, ses conseils précieux, ses motivations qui nous ont poussée à aller aussi loin, pour sa bienveillance, sa gentillesse, son soutien, et son humanisme. Nos vifs remerciements vont également aux membres de jury pour l'intérêt qu'ils ont porté à notre recherche en acceptant d'examiner notre travail. Enfin, nous tenons également à remercier toutes les personnes qui ont participé de près ou de loin à la réalisation de ce travail.

Sommaire

Remerciements	i
Sommaire	ii
Liste des Figures	v
Liste des Tableaux.....	vii
Introduction Générale.....	9
Chapitre 1: Maintenance prédictive et PHM.....	10
1.1 INTRODUCTION	11
1.2 Définition de la maintenance	11
1.3 rôle de la maintenance dans l'industrie	11
1.4 objectifs et les avantages de la maintenance industrielle efficace	12
1.4.1 Objectifs de la maintenance industrielle efficace	12
1.4.2 Avantages de la maintenance industrielle efficace	12
1.5 Types de maintenance industrielle.....	13
1.5.1 Maintenance corrective.....	13
Maintenance corrective palliative	14
Maintenance corrective curative	14
1.5.2 Maintenance préventive.....	14
Trois formes de maintenance préventive peuvent être distinguées : Maintenance préventive systématique.....	14
Maintenance préventive conditionnelle	15
Maintenance préventive prévisionnelle.....	16
1.6 Maintenance prédictive dans l'industrie.....	16
1.7 PHM	17
1.7.1 Définition de PHM	17
1.7.2 Historique de PHM	18
1.7.3 Architecture de PHM.....	19
Détection	19
Diagnostic	19
Pronostic	19
Aide à la décision	19
1.7.4 Avantages du PHM.....	20
1.8 Conclusion	21
Chapitre 2: Pronostic guidée par les données.....	22
2.1 Introduction.....	23
2.2 pronostic industriel.....	23
2.2.1 Définition du pronostic	23
2.2.2 Dégradation vs Pronostic.....	25
2.3 Remaining Useful Life (RUL)	25
2.4 rôle du pronostic dans le processus de durée de vie.....	26
2.5 les approches du pronostic	26
2.5.1 Approche basée sur le modèle physique.....	28
Avantages et inconvénients de la première approche.....	28

2.5.2	Approche guidée par les données	29
2.5.3	Approche basée sur l'expérience	30
	Avantages et inconvénients de la troisième approche	31
2.6	Fondements et principes du pronostic guidé par les données	32
2.7	Collecte et préparation des données de surveillance	33
2.8	Analyse de données pour la prédiction de l'état de santé	34
2.9	Techniques d'apprentissage automatique pour le pronostic guidé par les données....	35
2.10	Conclusion	36
Chapitre 3: Étude bibliographique		37
3.1	Introduction.....	38
3.2	1 ^{er} étude: A hybrid ARIMA–SVM model for the study of the remaining useful life of aircraft engines (Celestino Ordóñez , 2019)	38
3.3	2 ^{ème} étude: Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network (Hinchi&Tkouat, 2018).....	39
3.4	3 ^{ème} étude : Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture (Ellefsen 2019).....	39
3.5	4 ^{ème} étude : A locally adaptive ensemble approach for data-driven prognostics of heterogeneous fleets (Samer Al-Dahidi, 2017) :	40
3.6	5 ^{ème} étude : Remaining useful life estimation in prognostics using deep convolution neural networks (Xiang Li, 2018).....	41
3.7	6 ^{ème} étude : Remaining useful life estimation of turbofan engines using adaptive fault detection learning (Soualhi, 2022).....	42
3.8	7 ^{ème} étude : Rotating machinery remaining useful life prediction scheme using deep-learning-based health indicator and a new RVM (Gang Zhang, 2021) :	44
3.9	8 ^{ème} étude : Data-driven intelligent predictive maintenance of industrial assets (Olga Fink 2020) :	45
3.10	9 ^{ème} étude : Data-driven Approach for Fault Prognostics of Industrial Systems-From Using No, Insufficient, to Multiple Historical Degradation Sequences (Abid , 2020) :.....	46
3.11	10 ^{ème} étude : Direct wind turbine drivetrain prognosis approach using Elman neural network (Sharaf Eddine Kramti,2018)	47
	Conclusion.....	48
Chapitre 4: Mise en œuvre d'un algorithme en vue de la sélection des PHI .49		
4.1	Introduction.....	50
4.2	METHODOLOGIE DE MISE EN OUVRE PRONOSTIC GUIDE PAR LES DONNEES	50
4.3	apprentissage hors ligne	50
4.4	PRESENTATION DES DONNEES	51
4.5	Type de moteurs.....	51
4.6	Matlab et Programation.....	52
	4.6.1 Matlab.....	52
	4.6.2 Données des capteurs traitées	52
4.7	ETUDE de cas (L'ensemble C-MAPSS)	54
	Travail précédent :	54
4.7.1	Sélection du PHIOff	54

4.7.2	Programmation	57
	Monotonie	57
	Trendabilité	57
	prévisibilité.....	57
	Mesure composé	58
	Exécution de programme	58
	Classification des résultats de exécution de programme par excel	59
4.8	Résultats et discussions.....	61
4.8.1	Génération de matrice SVM finale pour classification des capteurs :.....	61
4.9	Conclusion	62
	Conclusion générale et perspectives	63
	Bibliographie.....	65

Liste des Figures

Figure 1-1	Forme de maintenance selon la norme NF EN 13306 (2001) [EN101] ...	13
Figure 1-2	Maintenance systématique	15
Figure 1-3	Maintenance conditionnelle	16
Figure 1-4	Détection, diagnostic et pronostic dans les systèmes de maintenance intelligente (Nabila, 2016).....	20
Figure 2-1	Résumé de la norme ISO 13381-1 : 2004 Étapes Principales	24
Figure 2-2	Définition de l'intervalle RUL.....	25
Figure 2-3	Les approches du prognostic(Koujouk,2010).....	27
Figure 3-1	Diagrammes de dispersion montrant le RUL réel par rapport au RUL prédit (CelestinoOrdóñez , 2019)	38
Figure 3-2	Signal vibratoire de roulement 3-3 (b) Signal vibratoire de roulement 1-339	
Figure 3-3	Structure d'architecture profonde semi-supervisée proposée	40
Figure 3-4	Organigramme de l'approche d'ensemble de commutation adaptative.	41
Figure 3-5	Quatre exemples de prédictions de la durée de vie restante (RUL) pour les unités de moteur de test dans FD001.....	42
Figure 3-6	Données fusionnées globales des trajectoires totales	43
Figure 3-7	RUL estimé a l'aide d'un temps de prédiction unique	43
Figure 3-8	RUL estimé a l'aide d'un temps de prédiction adaptatif	44
Figure 3-9	Schéma de l'RUL proposée	45
Figure 3-10	Exemples de prédiction de la durée de vie utile restante (RUL) pour le filtre avec de petites et grandes particules.....	47
Figure 3-11	Évaluation de caractéristiques statistiques dans le domaine temporel à l'aide de métriques de monotonie, de tendance et de pronosticabilité.....	48
Figure 4-1	Méthodologie de mise en œuvre du pronostic guidée par les données (Motrani, 2022).....	50
Figure 4-2	Colonne des moteurs.....	53
Figure 4-3	Colonne des cycles.....	53
Figure 4-4	Colonnes des conditions	53
Figure 4-5	Colonnes des capteurs.....	54
Figure 4-6	Signaux sans signification de dégradation.....	55
Figure 4-7	Signaux significatifs de dégradation.....	56
Figure 4-8	Graphe des quatre types de mesures	58
Figure 4-9	Onglet apps	60
Figure 4-10	Classification learner onglet	60

Figure 4-11 Classification par Matrice SVM62

Liste des Tableaux

Tableau 1 Calcul des quatre mesures	59
Tableau 2 état des mesures	59
Tableau 3 Classification learner de fichier Excel	61

Introduction Générale

Au fil des années, la technologie s'est développée de manière considérable dans de nombreux domaines en réponse aux besoins de la population, tels que l'industrie.

L'industrie a bénéficié de la mise en œuvre de nouvelles technologies depuis toujours. Cela a contribué à prospérer les cultures et les villes, et les a propulsées vers de nouveaux horizons. Une petite partie, mais très importante, de l'industrie est la maintenance.

Il va sans dire que la maintenance est essentielle dans ce domaine. Sans une surveillance continue de l'industrie, celle-ci peut s'effondrer et déclarer faillite.

Dans ce travail, nous nous concentrons sur la mise en place d'un programme de maintenance préventive qui fonctionne comme un système de prévision basé sur les données pour les turboréacteurs industriels équipés de capteurs. Ce programme génère une matrice SVM qui permet une interprétation visuelle des prédictions basées sur les lectures des capteurs, montrant soit une dégradation, soit l'absence de dégradation.

Ce travail est réalisé à l'aide de MATLAB, un logiciel permettant l'écriture et la simulation de programmes. C'est l'une des applications les plus courantes utilisées à des fins de prévision.

Le mémoire se compose de quatre chapitres :

- Le premier chapitre présente une étude générale et une définition de la maintenance prédictive et de la gestion de la santé (PHM - Prognostic and Health Management).
- Le deuxième chapitre focalise sur une étude approfondie du concept de prévision basée sur les données et de sa mise en œuvre, ainsi que de ses avantages et inconvénients.
- Le troisième chapitre est une étude bibliographique de dix recherches précédentes réalisées dans ce domaine (pronostic et PHM).
- Le quatrième chapitre présente les tests finaux et les résultats de notre programme MATLAB, montrant la matrice SVM (Support Vector Machine) souhaitée.

En fin une conclusion générale.

Chapitre 1: Maintenance prédictive et PHM

1.1 INTRODUCTION

Dans ce chapitre, nous présenterons une idée générale de la maintenance ainsi que la maintenance prédictive, son objectif ainsi que ses avantages. De plus, nous définirons la gestion de la santé (PHM) et son architecture, ainsi que ses avantages.

1.2 DÉFINITION DE LA MAINTENANCE

La maintenance est définie selon la Norme (NFEN13306, 2017) « *Un ensemble de toutes les actions techniques, administratives et de management durant le cycle de vie d'un bien, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise* ».

La maintenance industrielle fait référence à l'ensemble des activités planifiées et non planifiées visant à préserver, rétablir ou améliorer les performances des équipements, installations et systèmes industriels. Elle englobe des tâches telles que l'inspection, la réparation, le remplacement et la gestion des actifs, dans le but de garantir la disponibilité, la fiabilité et la durée de vie des équipements industriels. (Balakrishnan, 2013)

1.3 ROLE DE LA MAINTENANCE DANS L'INDUSTRIE

Le rôle de la maintenance dans l'industrie est essentiel pour assurer le bon fonctionnement des équipements, des installations et des systèmes industriels. Elle contribue à maintenir la disponibilité, la fiabilité et la performance des actifs, ce qui permet de garantir une production continue et d'optimiser l'efficacité opérationnelle. (Campbell, 2010)

La maintenance industrielle joue plusieurs rôles clés dans l'industrie, tels que :

- Maximisation de la disponibilité : La maintenance vise à minimiser les temps d'arrêt non planifiés en assurant la disponibilité des équipements essentiels à la production. Cela permet d'éviter les perturbations dans la chaîne de production et de répondre à la demande des clients de manière fiable.
- Préservation de la fiabilité : La maintenance préventive permet de préserver la fiabilité des équipements en réalisant des activités planifiées telles que l'inspection, la lubrification, le nettoyage, le remplacement des pièces usées, etc. Cela aide à réduire les risques de défaillance et à maintenir les performances optimales des actifs.
- Réduction des coûts d'exploitation : Une maintenance efficace permet de minimiser les coûts d'exploitation à long terme en évitant les réparations d'urgence coûteuses et en

optimisant l'utilisation des ressources. Elle contribue également à prolonger la durée de vie des équipements, ce qui réduit les coûts de remplacement prématuré.

- Amélioration de la sécurité : La maintenance inclut des activités de vérification et d'entretien des équipements pour garantir leur conformité aux normes de sécurité. Elle contribue à assurer un environnement de travail sûr pour les employés et à prévenir les accidents liés à des défaillances d'équipement.
- Optimisation des performances : La maintenance peut jouer un rôle actif dans l'optimisation des performances des équipements en proposant des améliorations, des modifications ou des mises à niveau technologiques. Cela permet d'augmenter l'efficacité, la productivité et la qualité des opérations industrielles.

1.4 OBJECTIFS ET LES AVANTAGES DE LA MAINTENANCE INDUSTRIELLE EFFICACE

La maintenance industrielle efficace vise à atteindre plusieurs objectifs clés et offre de nombreux avantages pour les entreprises. Voici un aperçu des objectifs et des avantages de la maintenance industrielle efficace :

1.4.1 Objectifs de la maintenance industrielle efficace

- Maximiser la disponibilité des équipements pour assurer une production continue.
- Prévenir les pannes et les défaillances en réalisant des activités de maintenance préventive.
- Réduire les temps d'arrêt non planifiés et les coûts associés.
- Prolonger la durée de vie des équipements en assurant leur entretien régulier.
- Améliorer la sécurité des travailleurs en garantissant le bon fonctionnement des équipements conformément aux normes de sécurité.

1.4.2 Avantages de la maintenance industrielle efficace

- Augmentation de la productivité : Une maintenance efficace permet une utilisation optimale des équipements, réduisant ainsi les temps d'arrêt et augmentant la productivité globale de l'entreprise.
- Réduction des coûts d'exploitation : En évitant les pannes coûteuses, les réparations d'urgence et les remplacements prématurés, la maintenance industrielle efficace contribue à réduire les coûts d'exploitation à long terme.

- Amélioration de la qualité des produits : La maintenance préventive garantit que les équipements fonctionnent de manière optimale, ce qui permet de maintenir des niveaux élevés de qualité des produits.
- Augmentation de la sécurité : Une maintenance régulière et préventive réduit les risques d'accidents liés aux défaillances d'équipement, assurant ainsi un environnement de travail plus sûr pour les employés.
- Optimisation des ressources : Une maintenance efficace permet d'allouer les ressources de manière plus efficace en évitant les réparations d'urgence et en planifiant les activités de maintenance de manière proactive. (Gulati, 2012)

1.5 TYPES DE MAINTENANCE INDUSTRIELLE

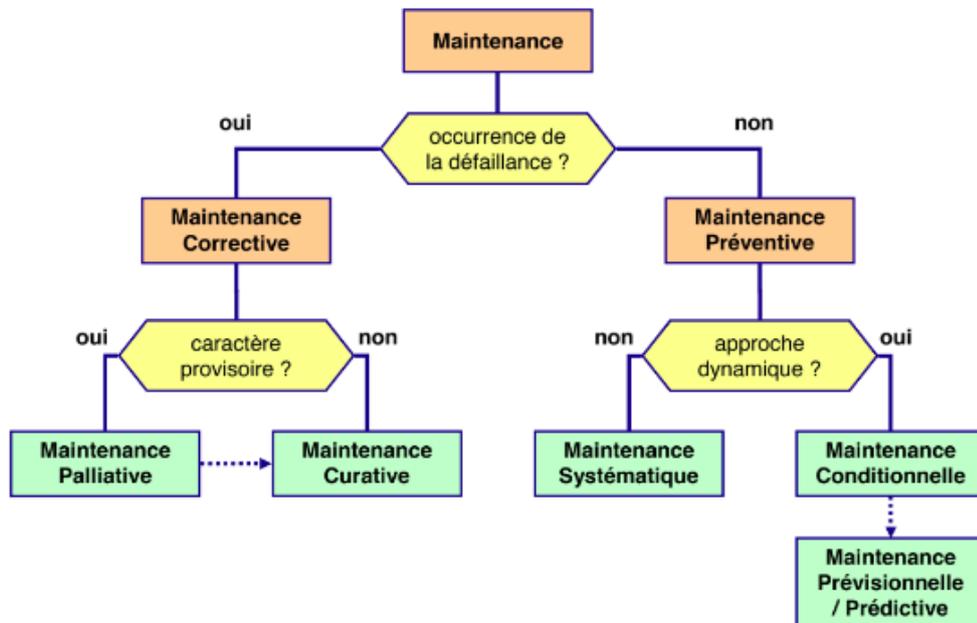


Figure 1-1 Forme de maintenance selon la norme NF EN 13306 (2001) [EN101]

1.5.1 Maintenance corrective

La maintenance corrective est un type de maintenance qui vise à rétablir le fonctionnement normal d'un équipement, d'un système ou d'une installation après une panne ou une défaillance. Elle implique la prise d'actions correctives pour réparer les défauts ou les dysfonctionnements détectés. (Don Nyman, 2011)

On distingue deux types de maintenance corrective sont :

Maintenance corrective palliative

Maintenance corrective ou réactive est basée sur une action a posteriori, c'est-à-dire après l'apparition d'un défaut (Remplacement d'une pièce défectueuse, réparation d'un circuit électrique, réinitialisation d'un système informatique, réparation d'un équipement mécanique)

Selon la norme EN NF 13306 (2017) (NFEN13306, 2017) :

« Maintenance exécutée après détection d'une panne et destinée à rétablir un bien dans un état dans lequel il peut accomplir une fonction requise ».

Maintenance corrective curative

Ce type de maintenance vise à effectuer des réparations spécifiques pour corriger une panne ou une défaillance identifiée. Les réparations peuvent inclure le remplacement de composants défectueux, la réparation de circuits électriques, le réalignement de pièces, etc.

1.5.2 Maintenance préventive

La maintenance préventive est basée sur une action a priori et son objectif principal est d'éviter le problème avant que le défaut ne se produise. Exemple (Vérification et remplacement régulier des filtres à air, lubrification des machines et des équipements, calibrage des instruments de mesure, nettoyage et dépoussiérage des équipements électroniques, inspection visuelle et recherche de fuites)

La norme européenne (NFEN13306, 2017) définit la maintenance préventive comme : « *Maintenance destinée à évaluer et/ou atténuer la dégradation et réduire la probabilité de défaillance d'un bien* ».

La maintenance préventive définit un ensemble d'actions réalisées avant la panne et destinées à éviter les pannes ou la dégradation d'une machine.

Trois formes de maintenance préventive peuvent être distinguées : Maintenance préventive systématique

Maintenance préventive exécutée à des intervalles de temps préétablis ou selon un nombre défini d'unités d'usage mais sans contrôle préalable de l'état du bien (NFEN13306, 2017).

Même si le temps est l'unité la plus répandue, d'autres unités peuvent être retenues telles que : la quantité de produits fabriqués, la longueur de produits fabriqués, la distance parcourue, la masse de produits fabriqués, le nombre de cycles effectués, etc

Cette périodicité d'intervention est déterminée à partir de la mise en service ou après une révision complète ou partielle.

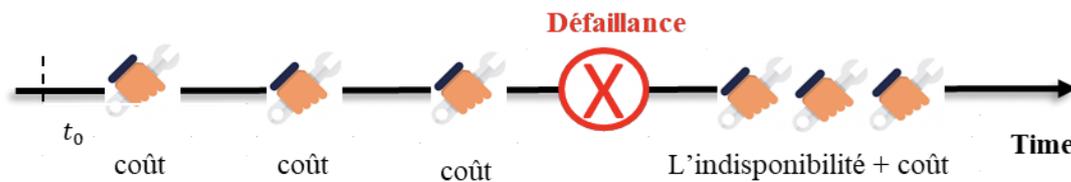


Figure 1-2 Maintenance systématique

Maintenance préventive conditionnelle

Maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent. La surveillance du fonctionnement et des paramètres peut être exécutée selon un calendrier, ou à la demande, ou de façon continue (NFEN13306, 2017).

Remarque: La maintenance conditionnelle est donc une maintenance dépendante de l'expérience et faisant intervenir des informations recueillies en temps réel.

La maintenance préventive conditionnelle se caractérise par la mise en évidence des points faibles. Suivant le cas, il est souhaitable de les mettre sous surveillance et, à partir de là, de décider d'une intervention lorsqu'un certain seuil est atteint. Mais les contrôles demeurent systématiques et font partie des moyens de contrôle non destructifs.

- ❖ Le niveau et la qualité de l'huile
- ❖ Les températures et les pressions
- ❖ La tension et l'intensité des matériels électrique
- ❖ Les vibrations et les jeux mécaniques

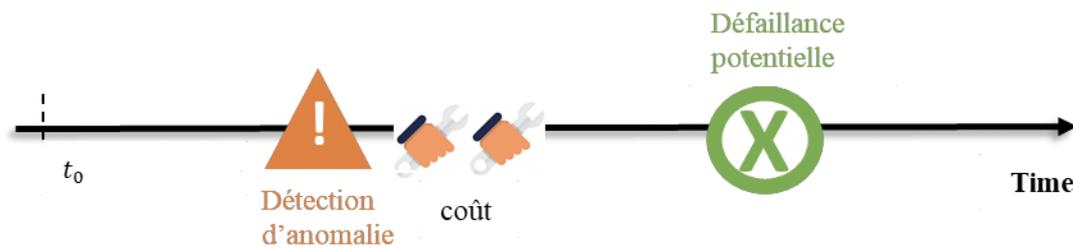


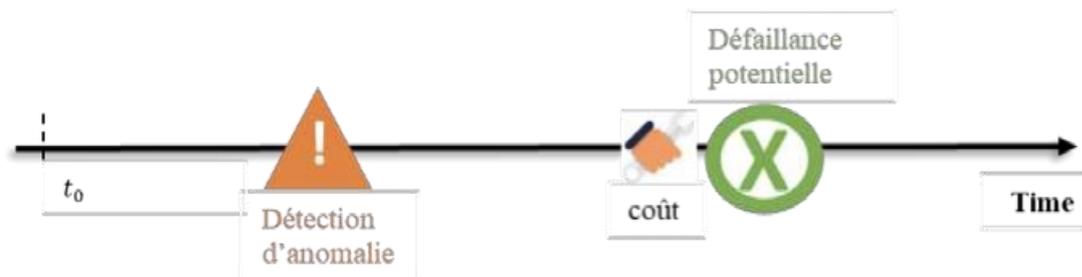
Figure 1-3 Maintenance conditionnelle

Maintenance préventive prévisionnelle

La maintenance préventive prévisionnelle, également appelée maintenance prédictive, est une stratégie de maintenance qui consiste à anticiper les pannes et les défaillances des équipements en se basant sur des données et des analyses prédictives. Elle repose sur la surveillance continue des paramètres de performance et des indicateurs de santé des équipements afin de planifier les activités de maintenance avant qu'une panne ne survienne.

La maintenance préventive prévisionnelle utilise des techniques telles que la surveillance des vibrations, l'analyse des lubrifiants, la thermographie infrarouge, les inspections visuelles, les analyses de défaillance, etc., pour détecter les signes précurseurs de défaillance et prendre des mesures de maintenance appropriées avant que la défaillance ne se produise.

Cette approche prédictive permet de réduire les temps d'arrêt imprévus, d'optimiser l'utilisation des ressources et de prolonger la durée de vie des équipements en effectuant des interventions de maintenance ciblées et planifiées. (Palmer, 2013)



1.6 MAINTENANCE PRÉDICTIVE DANS L'INDUSTRIE

La maintenance prédictive est une stratégie de maintenance qui repose sur l'utilisation de données en temps réel, de capteurs et d'outils d'analyse pour surveiller et prédire l'état de santé des équipements industriels. Elle vise à anticiper les pannes et les défaillances en identifiant les signaux précurseurs de problèmes potentiels, permettant ainsi une planification optimisée des activités de maintenance.

En utilisant des techniques telles que l'analyse vibratoire, l'analyse des signatures sonores, la surveillance des températures, la surveillance des fluides, la télémétrie, l'apprentissage automatique et d'autres méthodes d'analyse de données, la maintenance prédictive permet de détecter les dégradations ou les défaillances imminentes des équipements.

Les avantages de la maintenance prédictive dans l'industrie incluent :

la réduction des temps d'arrêt imprévus, l'optimisation de la planification des ressources, l'augmentation de la durée de vie des équipements, l'amélioration de la sécurité des travailleurs et la réduction des coûts de maintenance globaux. (Campbell, 2010)

A ce stade, notre travail s'intégrera dans les stratégies de maintenance prédictive. En effet, de nombreux auteurs ont mis en évidence que la maintenance prévisionnelle est la plus adaptée pour optimiser l'utilisation d'un système jusqu'au terme de sa vie utile.

L'ensemble des méthodes, des techniques et des procédures à mettre en œuvre pour réaliser une maintenance prédictive efficace, prend en anglais le terme PHM (Prognostic Health Management) (Sandborn & Wilkinson, 2007; Scanff et al., 2007).

1.7 PHM

1.7.1 Définition de PHM

La définition de PHM (Prognostics and Health Management) ou pronostique et gestion de l'état de santé en français, est un domaine de l'ingénierie qui se concentre sur la surveillance, la prédiction et la gestion de l'état de santé des systèmes, équipements et composants industriels.

Le PHM intègre des techniques de surveillance en temps réel, d'analyse des données, de modélisation et de prédiction pour évaluer l'état de santé des actifs industriels, détecter les anomalies, prédire les défaillances potentielles et fournir des informations sur les actions de maintenance à entreprendre.

L'objectif principal du PHM est d'optimiser la performance, la fiabilité, la disponibilité et la durée de vie des équipements industriels en réduisant les temps d'arrêt imprévus, en planifiant de manière proactive les activités de maintenance et en prenant des décisions éclairées basées sur l'état réel des actifs.

Le PHM repose sur des technologies telles que la surveillance de capteurs, l'analyse des vibrations, l'analyse des signaux, la maintenance prédictive, l'apprentissage automatique, la modélisation des systèmes et d'autres méthodes avancées d'analyse des données.

Il convient de noter que le PHM est souvent utilisé dans des secteurs industriels tels que l'aérospatiale, l'énergie, l'automobile, l'industrie manufacturière, la défense et d'autres industries où la maintenance proactive et la gestion de l'état de santé des actifs sont cruciales pour assurer des performances optimales et minimiser les coûts. (Kim, 2017)

1.7.2 Historique de PHM

Le domaine du Pronostique et de la Gestion de l'État de Santé (PHM) a évolué au fil du temps pour répondre aux besoins croissants de surveillance, de prédiction et de maintenance proactive des équipements industriels. Voici un bref aperçu de l'historique du PHM :

- Début des années 1960 : Les premières recherches sur le pronostic ont commencé à émerger dans le domaine de l'aérospatiale et de l'industrie de la défense. Les premières approches de pronostic se concentraient principalement sur la prédiction de la durée de vie résiduelle des composants critiques.
- Années 1980-1990 : Le PHM a commencé à gagner en importance dans l'industrie grâce aux avancées technologiques, notamment dans les domaines de la surveillance des capteurs, de l'informatique et de l'analyse des données. Les premières applications commerciales du PHM ont été introduites dans l'industrie de l'aérospatiale et de la défense pour la surveillance des systèmes critiques.
- Années 2000 : Avec les progrès rapides de l'informatique et de l'intelligence artificielle, le PHM a connu une croissance significative. Les capacités de collecte de données en temps réel et les algorithmes d'apprentissage automatique ont permis des améliorations importantes en matière de surveillance, de prédiction et de maintenance proactive. Le PHM s'est étendu à d'autres industries telles que l'énergie, l'automobile, l'industrie manufacturière et les services publics.
- Années 2010 et au-delà : Le PHM continue de se développer avec des avancées continues dans les technologies de l'Internet des objets (IdO), de l'analyse des données massives (big data), de l'apprentissage automatique avancé et de l'intelligence artificielle. De nouvelles applications du PHM émergent dans divers secteurs, notamment la santé, les infrastructures et les transports.
- Aujourd'hui, le PHM est considéré comme une composante essentielle de la maintenance prédictive et de la gestion proactive des actifs industriels. Il permet aux entreprises de surveiller en temps réel l'état de santé de leurs équipements, d'anticiper

les défaillances potentielles, de planifier les activités de maintenance et d'optimiser la performance opérationnelle. (Kim, 2017)

1.7.3 Architecture de PHM

Détection

Les sorties des capteurs et les observations des opérateurs sont continuellement comparées aux sorties des modèles des comportements nominaux préalablement construits pour détecter d'éventuelles anomalies sur le système. La détection des anomalies nécessite différents seuils définis en fonction de critères (performance, sécurité, etc.) établis par l'exploitant du système.

Diagnostic

Il correspond à la localisation et l'identification des causes des anomalies ou défaillances constatées sur le système. Il s'appuie sur une connaissance fine des composants du système, des interactions entre les composants, des conditions de fonctionnement et environnementales et du contexte dans lequel évolue le système.

Pronostic

Ce module s'appuie sur les résultats de la détection et éventuellement sur ceux du diagnostic pour prédire la durée de fonctionnement avant défaillance du système. Cette prédiction nécessite de connaître l'état actuel du système et ses futures conditions d'utilisation.

Aide à la décision

Les informations et les connaissances capitalisées à partir des modules précédents sont exploitées par ce module pour définir les actions à mettre en place pour permettre la conduite du système et assurer la continuité de ses fonctions attendues. Les actions recommandées peuvent être de type reconfiguration des lois de commande suite à une anomalie ou défaillance, accommodation de la situation courante, arrêt pour maintenance, arrêt d'urgence, etc. (Nabila, 2016).

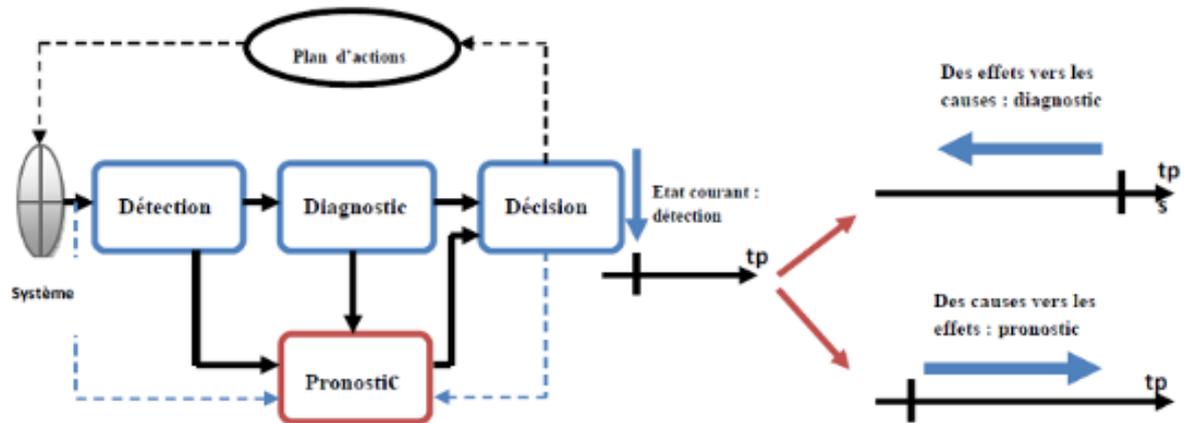


Figure 1-4 Détection, diagnostic et pronostic dans les systèmes de maintenance intelligente (Nabila, 2016)

1.7.4 Avantages du PHM

Le PHM semble très convaincant en raison de ses divers avantages qui sont énoncés ci-dessous :

- Augmentation de la durée de vie des systèmes,
- Evitement de pannes et réduction du nombre de défaillances imprévues et catastrophiques,
- 1. Prévision des interventions coûteuses de maintenance,
- Réduction des coûts de maintenance,
- 2. Amélioration de la gestion des pièces de rechange, des outils et des ressources humaines,
- Amélioration de l'efficacité opérationnelle et, par conséquent, la productivité des usines.
- 3. Amélioration de la sécurité des opérateurs et de l'environnement ;

Bien que le PHM soit une philosophie éprouvée, avec de nombreuses réussites, certaines mises en œuvre échouent également. La principale raison est le manque de planification et de soutien de la part de la direction, ce qui est essentiel à la réussite de tout programme. Tandis que la bonne planification a un impact sur la productivité des machines, leur performance et donc sur le résultat et les coûts de production.

1.8 CONCLUSION

En conclusion, le concept de PHM et de maintenance prédictive est au cœur de notre travail, c'est le concept principal de notre étude. Dans le prochain chapitre, nous introduirons l'idée de pronostic basé sur les données, qui est nécessaire pour atteindre notre résultat final.

Chapitre 2: Pronostic guidée par les données

2.1 INTRODUCTION

L'introduction du pronostic guidé par les données a révolutionné le domaine de la maintenance prédictive en permettant aux entreprises de prédire les défaillances et d'estimer la durée de vie restante de leurs équipements et systèmes industriels. Le pronostic guidé par les données repose sur l'analyse et l'exploitation des données de surveillance collectées à partir de capteurs, de systèmes de surveillance en temps réel et d'autres sources pertinentes.

Grâce aux avancées technologiques telles que l'internet des objets (IdO), l'automatisation et l'intelligence artificielle (IA), les entreprises sont en mesure de collecter de grandes quantités de données en temps réel sur les performances, l'état de santé et l'utilisation des équipements. Ces données sont ensuite utilisées pour développer des modèles et des algorithmes prédictifs qui peuvent anticiper les défaillances potentielles, identifier les tendances de dégradation et prédire la durée de vie restante des équipements.

2.2 PRONOSTIC INDUSTRIEL

2.2.1 Définition du pronostic

Le terme pronostic trouve son origine dans le mot grec "progignôskein" qui signifie "savoir d'avance". Le pronostic industriel est appelé prédiction de la durée de vie d'un système et correspond au dernier niveau de classification des méthodes de détection des dommages introduit par (D.L. & BANJEVIC., 2006).

Le pronostic peut également être défini comme une mesure de probabilité : un moyen de quantifier le risque qu'une machine fonctionne sans faute ou panne jusqu'à un certain temps. Cette « valeur pronostique probabiliste » est d'autant plus intéressante que le défaut ou la défaillance peut avoir des conséquences catastrophiques (par exemple une centrale nucléaire) et que le responsable de la maintenance doit savoir si les intervalles d'inspection sont appropriés. Cependant, un petit nombre d'articles abordent cette connotation pour le pronostic

Enfin, bien qu'il existe quelques divergences dans la littérature, le pronostic peut être défini comme suit : "le pronostic est l'estimation du temps de défaillance et du risque pour un ou plusieurs modes de défaillance existants et futurs" (Lin & Makis, 2003).

Dans cette connotation, le pronostic est également appelé "prédiction de la durée de vie d'un système" car il s'agit d'un processus dont l'objectif est de prédire la durée de vie restante (RUL) avant une défaillance. Les principales étapes définies dans cette norme sont résumées dans la figure 2-1.



Figure 2-1 Résumé de la norme ISO 13381-1 : 2004 Étapes Principales

La première étape consiste à surveiller le système par un ensemble de capteurs ou d'inspections réalisés par les opérateurs. Les données surveillées sont ensuite prétraitées afin d'être utilisées par le module Diagnostic. La sortie de ce module identifie le mode de fonctionnement réel. Cet état est ensuite projeté dans le futur, en utilisant des outils adéquats, afin de prédire l'état futur du système. Le point d'intersection entre la valeur de chaque paramètre ou caractéristique projetée et son seuil d'alarme correspondant conduit à ce que l'on appelle RUL (durée de vie utile restante) du système

Enfin, des actions de maintenance appropriées peuvent être prises en fonction du RUL estimé. Ces actions peuvent viser à éliminer l'origine d'une panne qui peut conduire le système à évoluer vers un mode de défaillance critique, retarder l'instant d'une panne par certaines actions de maintenance ou simplement arrêter le système si cela est jugé nécessaire. Chaque système ou composant d'un système passe par trois périodes au cours de sa vie de fonctionnement. La dernière phase de chaque vie du système représente la période de dégradation conduisant à une défaillance par détérioration progressive. Il est important de prédire, à chaque instant, la durée de vie restante afin d'éviter les défauts coûteux et d'éviter les pannes catastrophiques.

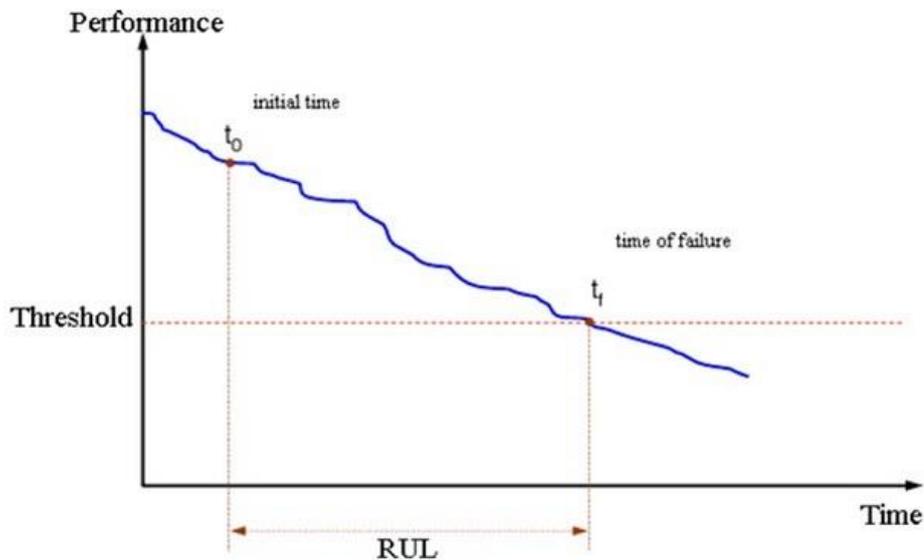


Figure 2-2 Définition de l'intervalle RUL

2.2.2 Dégradation vs Pronostic

Le diagnostic et le pronostic sont deux mots d'origine grecque. Au sens étymologique, le diagnostic est l'acquisition de la connaissance à partir de signes observables, alors que le pronostic est la précognition ou la connaissance préalable. Au sens automatique, le sens des deux mots est plus précis et technique. Le diagnostic consiste en la régression dans le temps pour expliquer pourquoi le système est dans un état donné à l'instant t . Le pronostic consiste à anticiper dans le temps afin de prédire l'état futur du système à l'instant $t + \Delta t$. Le diagnostic et le pronostic sont deux processus parallèles qui peuvent être utilisés de manière complémentaire ou séparée. (Abdo et al., 2010).

2.3 REMAINING USEFUL LIFE (RUL)

Remainin gUseful Life (RUL), également connu en français sous le nom de durée de vie utile restante, est une mesure utilisée dans le domaine de la maintenance pour estimer la période de temps restante avant qu'un équipement, un système ou un composant ne dépasse son seuil de performance acceptable ou ne subisse une défaillance.

La durée de vie utile restante est déterminée en évaluant l'état actuel de l'équipement, en prenant en compte les données de surveillance, les tendances de dégradation, les modèles de vieillissement et d'autres facteurs pertinents. Elle est généralement exprimée en unité de temps, telle que des heures, des jours, des mois ou des cycles.

L'estimation de la durée de vie utile restante permet aux responsables de la maintenance de planifier les activités de maintenance de manière proactive. Cela inclut la programmation des

inspections, des réparations, des remplacements ou d'autres interventions nécessaires pour maintenir ou restaurer la performance de l'équipement.

L'objectif de la mesure de la durée de vie utile restante est d'optimiser l'utilisation des ressources de maintenance, d'éviter les temps d'arrêt imprévus, de maximiser la disponibilité des équipements et de prolonger leur durée de vie opérationnelle.

Il convient de noter que l'estimation de la durée de vie utile restante peut être influencée par des facteurs tels que les conditions d'exploitation, les modes de défaillance, l'historique de maintenance, les variables environnementales et d'autres paramètres spécifiques à l'équipement ou au système concerné.

La durée de vie utile restante est un élément clé dans la mise en œuvre de stratégies de maintenance prédictive et de gestion proactive des actifs. (Kim, 2017).

2.4 RÔLE DU PRONOSTIC DANS LE PROCESSUS DE DURÉE DE VIE

Le pronostic est un processus englobant une capacité de prédiction. C'est la capacité à estimer la durée de vie utile restante (RUL) de l'équipement en termes de son historique de fonctionnement et de son utilisation future. Prédire la RUL des systèmes industriels devient actuellement un objectif important pour les industriels sachant que la panne, dont les conséquences sont généralement très coûteuses, peut se produire soudainement.

Les stratégies classiques de maintenance ne sont pas plus efficaces et pratiques car elles ne prennent pas en compte l'état de fonctionnement instantané du produit. Adopter une maintenance systématique préventive par un remplacement fréquent pour augmenter la disponibilité du système est une stratégie coûteuse. L'introduction d'une approche pronostique en tant que maintenance « intelligente » consiste en l'analyse, la surveillance et le suivi de la santé, basés sur des mesures physiques à l'aide de capteurs.

Le RUL d'un système en service peut s'exprimer en heures de fonctionnement, en Kilomètres ou en cycles. Si nous pouvons prédire efficacement l'état des machines et des systèmes, des actions de maintenance peuvent être prises à l'avance. Un pronostic bon et fiable nécessite un diagnostic correct et fiable

2.5 LES APPROCHES DU PRONOSTIC

Diverses approches du pronostic ont été développées. Mettre au travail un processus de pronostic consiste à exécuter un ensemble de traitements à partir des informations saisies. Les différentes approches

du pronostic sont regroupées en fonction de leur applicabilité et de leur rendement économique. Ce sont trois familles :

- Une approche basée sur le modèle physique.
- Une approche guidée par les données.
- Une approche basée sur l'expérience.

La pyramide reproduite dans la figure met en évidence la hiérarchie de ces différentes familles. Selon Muller (Muller, 2005)

Le choix d'une famille d'approche se fait en répondant à deux questions :

- ✓ *Est-il possible de construire un modèle physique pour les mécanismes de dégradation?*
- ✓ *L'instrumentation de l'équipement est-elle suffisante pour évaluer un indicateur d'évolution de la dégradation ?*

Si la réponse à la première question est positive, la mise en œuvre d'une approche basée sur des modèles physiques est envisagée. De plus, si la réponse à la deuxième question est positive, une approche guidée par les données est possible. Dans le cas où la réponse aux deux questions est négative, une approche basée sur l'expérience est la meilleure solution. Une étude réalisée sur plus de 100 publications dans le domaine du pronostic montre que dans le secteur industriel, les approches guidées par les données et basées sur l'expérience ont mises en œuvre.

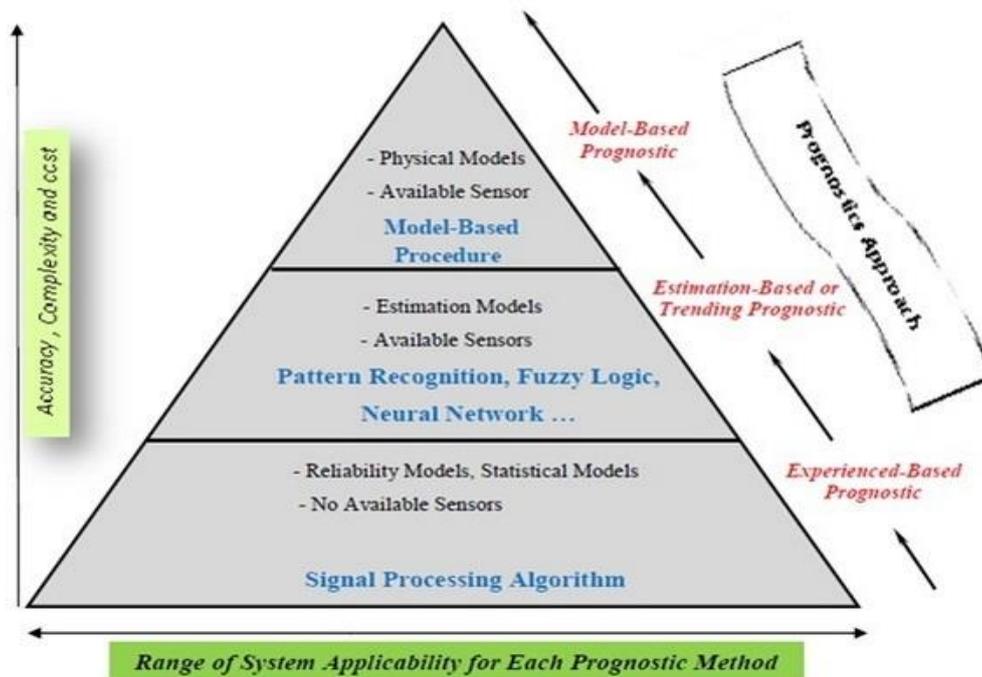


Figure 2-3 Les approches du pronostic(Koujouk,2010)

2.5.1 Approche basée sur le modèle physique

Le pronostic basé sur les modèles fait appel à une fonction mathématique connue de la dynamique de la dégradation, surveillée par un indicateur, conduisant à la défaillance d'un composant. Le résultat de la fonction pronostic implémentant ce type d'approche est le temps de vie résiduel ou RUL du composant.

La mise en œuvre est assez aisée si l'évolution dans le temps de l'indicateur associé à la dégradation est une fonction monotone. La dégradation est aussi souvent fonction du mode de fonctionnement des composants. Ainsi, lorsqu'un changement de mode de fonctionnement intervient dans l'utilisation du système, la fonction de dégradation doit être mise à jour pour une dégradation donnée. Le problème de ce type d'approche vient du fait qu'il faut disposer des indicateurs de surveillance de dégradation et de leur fonction d'évolution pour chaque mode de fonctionnement. Ceci n'est pas toujours possible.

En effet, il apparaît que les mesures émanant d'un dispositif à surveiller ne sont pas forcément pertinentes pour la surveillance de l'état de dégradation du système. Il apparaît donc que l'implémentation d'une fonction de pronostic sur un système doit être établie dès la conception afin de pouvoir spécifier et lister les données nécessaires à la mise en œuvre de ce type de résultats.

Des alternatives existent et nécessitent la construction d'un indicateur générique issu de différentes mesures qui mettent en œuvre des techniques de traitement du signal. Ces alternatives peuvent être utiles dans le cas où une surveillance des dégradations doit être établie sur un système déjà existant ne permettant pas d'évolution vers ce type de services ou ne pouvant pas accueillir de capteurs dont les mesures seraient utilisées à des fins de pronostic

Avantages et inconvénients de la première approche

Le principal avantage des approches basées sur des modèles est leur capacité à intégrer la compréhension physique du système surveillé. De plus, dans de nombreuses situations, les modifications du vecteur de caractéristiques sont étroitement liées aux paramètres du modèle et une correspondance fonctionnelle entre les paramètres de dérive et les caractéristiques pronostiques sélectionnées peuvent être établie. De plus, si la compréhension de la dégradation du système s'améliore, le modèle peut être adapté pour augmenter sa précision et pour résoudre les problèmes de performances subtils. Par conséquent, ils peuvent largement dépasser les approches basées sur les données (section suivante).

Mais cette relation fermée avec un modèle mathématique peut également être une faiblesse importante : il peut être difficile, voire impossible, d'attraper le comportement du système. De

plus, certains auteurs pensent que les outils de surveillance et de pronostic doivent évoluer comme le fait le système. (Luo et al., 2003, Dievart, 2010).

2.5.2 Approche guidée par les données

Le pronostic guidé par les données exploite les données des indicateurs de dégradation ou d'intervention de maintenance délivrés respectivement par le processus de surveillance et d'aide à la décision (données calorimétriques de calibrage, données spectrométriques, puissance, vibration, température, pression, débris d'huile, tension, etc.). Ce type de pronostic se fonde sur l'hypothèse que les caractéristiques statistiques des données sont relativement inchangées à moins qu'un défaut de fonctionnement ne se produise dans le système

L'implémentation d'une approche guidée par les données est relativement simple car elle ne requiert pas la connaissance formelle des mécanismes de dégradation. Elle permet de transformer simplement des données bruitées en informations pertinentes pour des décisions de pronostic. En outre, cette approche peut être adaptée à tout type d'application disposant de données suffisantes en quantité et qualité. En revanche, c'est là également sa principale limite :

l'efficacité d'une approche de pronostic guidée par les données dépend fortement de l'existence de ces données opérationnelles. Par ailleurs, le processus de surveillance conditionne également la justesse du pronostic par sa capacité à fournir une estimation fiable et précise de l'état de santé courant du système

Trois catégories de méthodes de pronostic guidé par les données sont recensées dans

. Elles sont distinguées par la nature des techniques exploitées :

- Le pronostic par analyse de tendance exploitant des modèles statistiques,
- Le pronostic par apprentissage automatique exploitation de modèles de type boîte noire issus de l'intelligence artificielle,
- Le pronostic basé sur un estimateur d'état.

Les approches basées sur les données nécessitent que les informations extraites des capteurs soient suffisantes en qualité et en quantité pour évaluer l'état actuel ou l'image de l'état actuel de la dégradation du système.

Le concept de cette approche consiste à collecter des informations et des données sur le système et à les projeter afin de prévoir l'évolution future de certains paramètres, descripteurs ou caractéristiques, et donc de prévoir les éventuelles erreurs probables. Sans être exhaustifs, les outils mathématiques utilisés dans cette approche sont principalement ceux utilisés par la communauté

de l'intelligence artificielle, à savoir : séries de prédiction temporelles, techniques d'analyse des tendances, réseaux de neurones, systèmes neuro-flous, modèles de Markov cachés et réseaux bayésiens dynamiques.

L'avantage de cette approche est que, pour un système bien surveillé, il est possible de prédire l'évolution future de la dégradation sans avoir besoin d'un modèle mathématique préalable de la dégradation. Cependant, les résultats obtenus par cette approche souffrent de précision et sont parfois considérés comme locaux (pour les réseaux de neurones et les méthodes neuro-floues). De plus, le système de surveillance doit être bien conçu pour assurer des résultats de pronostic acceptable.

Les approches basées sur les données utilisent des données réelles recueillies en ligne avec des capteurs ou par des mesures de l'opérateur pour approcher et suivre les caractéristiques révélant la dégradation des composants et prévoir le comportement global d'un système. En effet, dans de nombreuses applications, les données d'entrée / sortie mesurées sont la principale source d'une meilleure compréhension de la dégradation du système. Les approches fondées sur les données peuvent être divisées en deux catégories : les techniques d'intelligence artificielle (IA) (réseaux de neurones, systèmes flous, etc.) et les techniques statistiques (méthodes statistiques multi variées, discriminateurs linéaires et quadratiques, moindres carrés partiels, etc.)

2.5.3 Approche basée sur l'expérience

Cette approche est appelée approche pronostique basée sur l'expérience ou basée sur la probabilité ou statistique.

Il est nécessaire de ne pas pouvoir utiliser les deux approches précédentes. Il est basé sur une fonction de fiabilité ou sur un processus bayésien où les paramètres sont issus de l'expérience de retour ou de l'opinion d'experts. Ses inconvénients sont l'incapacité à traiter des systèmes complexes de nombreux composants et son principe binaire exclusif (succès / échec) plutôt que des états de dégradation continus.

Lorsque l'obtention d'un modèle physique d'un équipement est difficile et qu'il est impossible d'estimer la dégradation à partir des capteurs installés sur l'équipement, le pronostic basé sur l'expérience peut être la seule alternative. Cette forme de pronostic est la moins complexe mais nécessite un excellent retour d'expert sous forme de données historiques, de bases de connaissances ou de données d'experts. Cette expertise permet une modélisation stochastique ou probabiliste de la dégradation. C'est la forme la mieux adaptée aux systèmes complexes,

très difficiles à modéliser physiquement et dont les indicateurs de dégradation sont sensibles aux conditions d'utilisation.

Cette approche pronostique consiste à utiliser des modèles probabilistes ou stochastiques du phénomène de dégradation, ou du cycle de vie des composants, en prenant en compte les données et les connaissances accumulées par l'expérience pendant toute la période d'exploitation du système industriel.

Le modèle probabiliste peut être une simple fonction de probabilité ou une modélisation sous forme de processus stochastique. Dans ce cadre, les fonctions de probabilité les plus utilisées sont : la loi de Weibull, la loi exponentielle lorsque le taux de défaillance est supposé être constant et les lois normales, log-normales et de Poisson. Les paramètres de chaque loi sont estimés à partir des données collectées pendant toute la période d'exploitation (retour d'expérience, données de maintenance, etc.). Les modèles de processus stochastiques peuvent être markoviens ou semi-markoviens.

Les modèles basés sur l'expérience s'appuient sur des mesures de surveillance de la santé de la machine telles que le jugement expert, le modèle stochastique, le processus markovien, l'approche bayésienne, l'analyse de fiabilité, l'optimisation de la maintenance préventive, etc. Leur méthodologie pronostique s'avère simple mais inflexible face aux changements de comportement et d'environnement du système.

Avantages et inconvénients de la troisième approche

L'avantage de cette approche est qu'il n'est pas nécessaire d'avoir des modèles mathématiques complexes pour faire du pronostic. En outre, cette approche est facile à appliquer sur les systèmes pour lesquels des données importantes sont stockées dans une même norme qui facilite leur utilisation. Par exemple, une entreprise qui a créé pendant une longue période une base de données de production et de maintenance avec quelques règles et normes mineures pour le stockage des données peut facilement obtenir l'estimation des paramètres des lois de probabilité.

Cependant, le principal inconvénient de cette approche réside dans la quantité de données nécessaires pour estimer les paramètres des lois utilisées. En effet, une quantité considérable et importante de données d'exploitation est nécessaire pour déterminer les paramètres qui modélisent fidèlement le phénomène de dégradation ou le cycle de vie du système concerné. Par conséquent, cette approche ne peut être appliquée dans le cas de nouveaux systèmes pour lesquels il n'existe pas de données issues du retour d'expérience. L'autre type de problème est que dans la plupart des cas, il est nécessaire de filtrer et de prétraiter les données pour en extraire les données

utiles, car les données stockées ne sont pas toujours directement exploitables (par exemple, dans la même entreprise, deux opérateurs de maintenance peuvent entrez deux informations ou appréciations différentes pour le même problème résolu.

2.6 FONDEMENTS ET PRINCIPES DU PROGNOSTIC GUIDEN PAR LES DONNEES

Les fondements et principes du prognostic guidé par les données (data-driven prognostics) reposent sur plusieurs concepts clés. Voici quelques-uns des fondements et principes importants :

1. Données de surveillance : Le prognostic guidé par les données repose sur la collecte et l'analyse de données de surveillance provenant des équipements ou systèmes concernés. Ces données peuvent inclure des mesures de capteurs, des relevés d'état, des enregistrements de performances, des historiques de maintenance, des données environnementales et d'autres informations pertinentes.

2. Analyse des données: L'analyse des données est au cœur du prognostic guidé par les données. Elle implique l'utilisation de techniques d'apprentissage automatique, de statistiques, de modélisation mathématique et d'autres méthodes d'analyse avancées pour extraire des informations utiles des données de surveillance, identifier les modèles de dégradation, détecter les anomalies et prédire l'évolution future de l'état de santé.

3. Modèles de dégradation : Les modèles de dégradation sont utilisés pour représenter la relation entre les données de surveillance et l'état de santé des équipements. Ces modèles peuvent être basés sur des approches probabilistes, des techniques de régression, des modèles de série temporelle, des réseaux de neurones, etc. Ils permettent de prédire la dégradation future, d'estimer la durée de vie restante et de prendre des décisions de maintenance appropriées.

4. Prédiction de la durée de vie restante : L'un des objectifs clés du prognostic guidé par les données est d'estimer la durée de vie restante des équipements ou systèmes. Cela implique la prédiction du moment où un seuil de performance acceptable sera dépassé ou lorsque la probabilité de défaillance deviendra significative. Ces prédictions aident à planifier les activités de maintenance et à éviter les temps d'arrêt imprévus.

5. Intégration des données en temps réel : Le prognostic guidé par les données peut tirer parti de la collecte en temps réel des données de surveillance pour améliorer les prédictions et ajuster les modèles en fonction des nouvelles informations. Cela permet une prise de décision plus réactive et une maintenance plus proactive.

6. Validation et évaluation des modèles : Il est essentiel de valider et d'évaluer les modèles de pronostic guidé par les données pour s'assurer de leur précision et de leur fiabilité. Cela implique l'utilisation de métriques d'évaluation, de techniques de validation croisée et de comparaisons avec des données réelles pour vérifier la performance des modèles.

7. Amélioration continue : Le pronostic guidé par les données est un domaine en évolution constante. Les nouvelles technologies, les avancées de l'apprentissage automatique et les meilleures pratiques émergentes contribuent à l'amélioration continue des méthodes de pronostic guidé par les données.

Ces fondements et principes fournissent les bases nécessaires pour développer des modèles de pronostic guidé par les données efficaces et fiables, permettant ainsi une maintenance proactive et une gestion optimisée de l'état de santé des équipements industriels. (Gouriveau et al., 2017)

2.7 COLLECTE ET PREPARATION DES DONNEES DE SURVEILLANCE

La collecte et la préparation des données de surveillance sont des étapes cruciales dans le processus de pronostic guidé par les données. Voici quelques points importants à considérer :

1. Sélection des variables : Identifiez les variables pertinentes à surveiller en fonction des caractéristiques de l'équipement ou du système étudié. Ces variables peuvent inclure des mesures de capteurs, des paramètres de performance, des données environnementales, des historiques de maintenance, etc. Assurez-vous que les données sélectionnées sont directement liées à l'état de santé ou à la dégradation des équipements.

2. Collecte des données : Mettez en place un système de collecte de données approprié pour obtenir des mesures régulières et fiables. Cela peut inclure l'utilisation de capteurs, d'instruments de mesure, de systèmes de surveillance automatisés, etc. Assurez-vous que les données sont collectées à intervalles réguliers et en temps réel si possible.

3. Nettoyage des données : Avant d'analyser les données, effectuez des étapes de nettoyage pour éliminer les valeurs aberrantes, les données manquantes ou corrompues. Appliquez des techniques de nettoyage de données telles que l'interpolation, l'imputation de données manquantes ou la suppression des valeurs aberrantes afin d'obtenir un ensemble de données propre et fiable.

4. Normalisation des données : Pour faciliter l'analyse et la comparaison, normalisez les données en les ramenant à une échelle commune. Cela peut être fait en utilisant des techniques de normalisation telles que la mise à l'échelle min-max, la normalisation z-score, ou d'autres méthodes appropriées en fonction des caractéristiques des données.

5. Agrégation et fusion des données : Si les données sont collectées à partir de différentes sources ou capteurs, il peut être nécessaire de les agréger et de les fusionner pour former un ensemble de données cohérent. Assurez-vous d'aligner les échantillons temporels, de résoudre les éventuels problèmes de synchronisation et de traiter les incohérences potentielles entre les sources de données.

6. Stockage des données : Mettez en place un système de stockage des données qui permet une gestion efficace et sécurisée des ensembles de données de surveillance. Cela peut inclure l'utilisation de bases de données, de systèmes de gestion de données ou d'autres solutions adaptées à vos besoins spécifiques.

7. Documentation des métadonnées : Il est important de documenter les métadonnées associées aux données de surveillance, telles que la description des variables, les unités de mesure, les conditions de collecte, les informations sur les capteurs, etc. Cela facilite la compréhension ultérieure des données et garantit leur traçabilité.

La collecte et la préparation des données de surveillance nécessitent une attention particulière pour garantir la qualité et la fiabilité des données utilisées dans le processus de pronostic guidé par les données.(Kim, 2017)

2.8 ANALYSE DE DONNEES POUR LA PREDICTION DE L'ETAT DE SANTE

L'analyse de données joue un rôle essentiel dans la prédiction de l'état de santé des équipements ou systèmes dans le cadre du pronostic guidé par les données. Voici quelques techniques couramment utilisées pour effectuer cette analyse :

1. Analyse statistique : L'analyse statistique permet d'explorer les données de surveillance, d'identifier les tendances, les corrélations et les motifs significatifs. Des techniques telles que l'analyse descriptive, l'analyse de variance, la régression linéaire ou non linéaire, et d'autres méthodes statistiques peuvent être appliquées pour comprendre la relation entre les variables de surveillance et l'état de santé.

2. Analyse des séries temporelles : L'analyse des séries temporelles est utilisée pour étudier les données en fonction du temps. Elle permet de détecter les tendances, les modèles saisonniers, les fluctuations et les anomalies dans les données temporelles. Des méthodes telles que la modélisation ARIMA (AutoRegressive Integrated Moving Average), les modèles de régression temporelle, les filtres de Kalman et autres techniques d'analyse des séries temporelles peuvent être utilisées pour prédire l'évolution future de l'état de santé.

3. Méthodes d'apprentissage automatique : Les techniques d'apprentissage automatique, telles que les algorithmes de classification, de régression et de clustering, peuvent être appliquées pour développer des modèles prédictifs basés sur les données de surveillance. Des méthodes telles que les machines à vecteurs de support (SVM), les arbres de décision, les réseaux de neurones, les forêts aléatoires, et d'autres algorithmes d'apprentissage automatique peuvent être utilisées pour prédire l'état de santé futur en se basant sur les données historiques.

4. Méthodes d'apprentissage profond : Les méthodes d'apprentissage profond, telles que les réseaux de neurones profonds, les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN), sont utilisées pour capturer des motifs complexes et non linéaires dans les données de surveillance. Ces techniques sont souvent utilisées lorsque les données sont de grande dimension ou présentent des structures temporelles complexes.

5. Analyse de données multivariées : L'analyse de données multivariées permet de prendre en compte les interactions et les relations entre plusieurs variables de surveillance. Des techniques telles que l'analyse en composantes principales (ACP), l'analyse factorielle discriminante (AFD), l'analyse des dépendances canoniques (CDA) et d'autres méthodes multivariées peuvent être utilisées pour extraire des informations significatives et réduire la dimensionnalité des données.

Il convient de noter que le choix des techniques d'analyse de données dépendra des caractéristiques spécifiques des données de surveillance et des objectifs du pronostic guidé par les données. Il est souvent nécessaire d'expérimenter et de comparer différentes approches pour déterminer la méthode la plus appropriée pour prédire l'état de santé. (Kim, 2017)

2.9 TECHNIQUES D'APPRENTISSAGE AUTOMATIQUE POUR LE PROGNOSTIC GUIDE PAR LES DONNEES

Pour le pronostic guidé par les données, plusieurs techniques d'apprentissage automatique peuvent être utilisées pour développer des modèles prédictifs. Voici quelques-unes des techniques couramment utilisées :

1. Régression linéaire : La régression linéaire est une technique d'apprentissage automatique qui permet de modéliser la relation linéaire entre les variables d'entrée et la variable de sortie. Elle peut être utilisée pour prédire l'évolution future de l'état de santé en fonction des données de surveillance.

2. Machines à vecteurs de support (SVM) : Les SVM sont des algorithmes d'apprentissage supervisé utilisés pour la classification et la régression. Ils permettent de construire des frontières

de décision pour séparer les données en classes ou pour prédire des valeurs continues. Les SVM peuvent être appliquées pour prédire l'état de santé future en se basant sur les données historiques.

3. Réseaux de neurones : Les réseaux de neurones sont des modèles d'apprentissage automatique qui simulent le fonctionnement du cerveau humain. Ils peuvent être utilisés pour apprendre des relations complexes entre les variables d'entrée et de sortie. Les réseaux de neurones profonds, tels que les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN), sont souvent utilisés pour la prédiction de l'état de santé dans les applications de pronostic guidé par les données.

4. Arbres de décision : Les arbres de décision sont des modèles d'apprentissage automatique qui utilisent une structure d'arbre pour prendre des décisions basées sur des règles conditionnelles. Ils peuvent être utilisés pour prédire l'état de santé en évaluant différentes caractéristiques des données de surveillance et en suivant un cheminement dans l'arbre de décision.

5. Forêts aléatoires : Les forêts aléatoires sont des ensembles d'arbres de décision qui combinent plusieurs arbres pour obtenir des prédictions plus robustes et généralisées. Chaque arbre est construit sur un échantillon aléatoire des données d'entrée, ce qui réduit le risque de surajustement (overfitting) et améliore les performances prédictives.

6. Méthodes de clustering : Les méthodes de clustering, telles que le clustering k-means ou le clustering hiérarchique, peuvent être utilisées pour regrouper les données de surveillance en fonction de leurs similarités. Cela peut aider à identifier des sous-populations ou des schémas de dégradation spécifiques, ce qui peut être utile pour la prédiction de l'état de santé.

Il convient de noter que le choix de la technique d'apprentissage automatique dépendra des caractéristiques spécifiques des données de surveillance et des objectifs du pronostic guidé par les données. Il est recommandé de tester et d'évaluer différentes techniques pour déterminer celle qui offre les meilleures performances prédictives dans un contexte donné. (Kim, 2017)

2.10 CONCLUSION

En conclusion, nous avons abordé de manière théorique l'aspect du pronostic basé sur les données et ses perspectives et utilisations, ce qui nous offre l'approche nécessaire pour atteindre notre résultat final

Chapitre 3: Étude bibliographique

3.1 INTRODUCTION

Dans ce chapitre on va mentionner les différents travaux attribués dans ce domaine en étudiant les recherches bibliographiques déjà fait par des plusieurs experts académiques.

L'étude se fait sur dix différents travaux dans le cadre de pronostic basée sur les données.

3.2 1^{ER} ÉTUDE: A HYBRID ARIMA–SVM MODEL FOR THE STUDY OF THE REMAINING USEFUL LIFE OF AIRCRAFT ENGINES (CELESTINO ORDÓÑEZ , 2019)

Ce travail est une proposition d'un nouvel algorithme de prédiction de durée de vie (RUL) pour but de détection de réduction qui pourrait affecter le fonctionnement d'un moteur aéronef.

Le pronostic des variables d'entrée d'un capteur se fait a l'aide du modèle ARIMA, les résultats sont utilisés comme Co-variables d'un modèle SVM.

Les capacités prédictives sont supérieures à celles obtenus à l'aide de modèle VARMA.

Les résultats obtenus pourraient être appliquées aux véhicules aériens sans pilote (UAV).

Le diagramme dessous montre la différence entre le RUL prédit et le RUL réel.

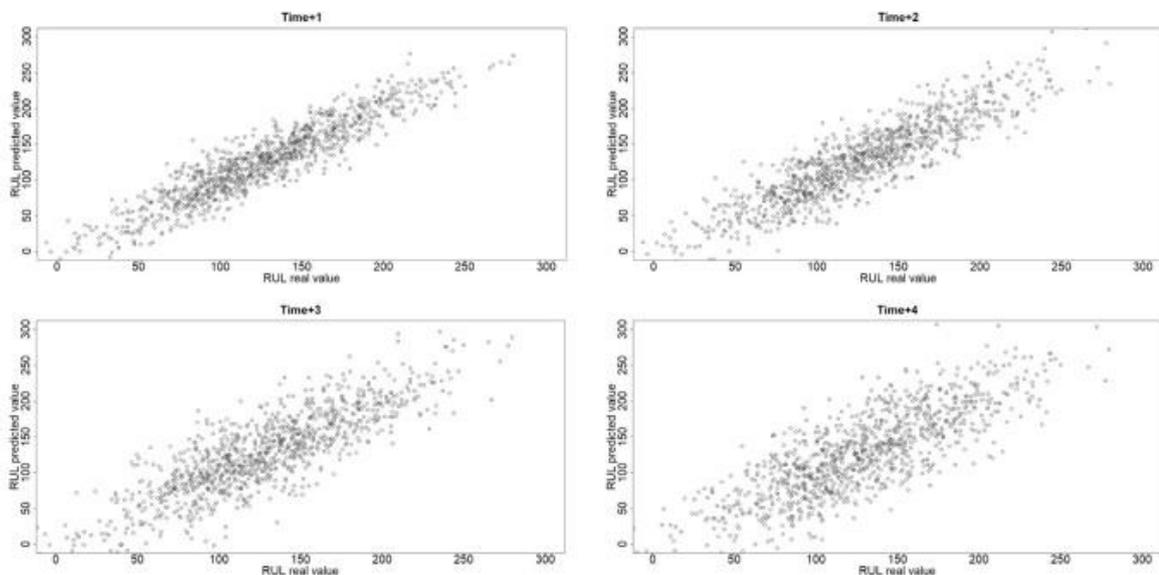


Figure 3-1 Diagrammes de dispersion montrant le RUL réel par rapport au RUL prédit (CelestinoOrdóñez , 2019)

3.3 2^{ÈME} ÉTUDE: ROLLING ELEMENT BEARING REMAINING USEFUL LIFE ESTIMATION BASED ON A CONVOLUTIONAL LONG-SHORT-TERM MEMORY NETWORK (HINCHI&TKIOUAT, 2018)

La figure ci-dessous montre le signal de vibration radiale de deux roulements testés pendant toute leur durée de vie.

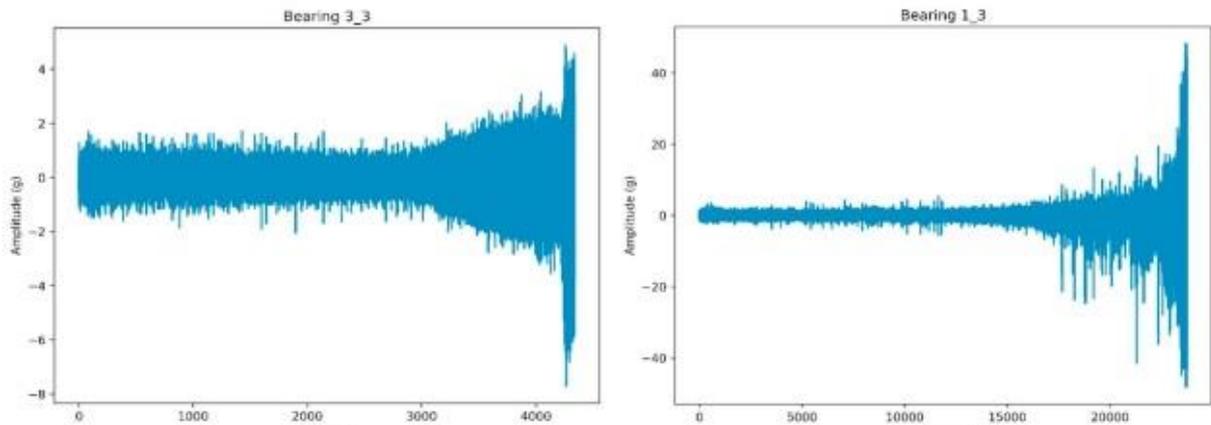


Figure 3-2 Signal vibratoire de roulement 3-3 (a) Signal vibratoire de roulement 1-3

On peut observer que les amplitudes des signaux vibratoires évoluent différemment dans le temps, d'où on observe la complexité de l'estimation RUL.

Cette étude propose un cadre profond intégré pour l'estimation de la RUL basé sur des unités récurrentes de convolution et de mémoire à court et long terme (LSTM).

Le réseau neuronal entraine les caractéristiques locales à partir des données de capteur en utilisant la couche de convolution, après une couche LSTM pour capturer les dégradations.

Le RUL est donc estimée en utilisant les sorties LSTM et la valeur de temps de prédiction.

3.4 3^{ÈME} ÉTUDE : REMAINING USEFUL LIFE PREDICTIONS FOR TURBOFAN ENGINE DEGRADATION USING SEMI-SUPERVISED DEEP ARCHITECTURE (ELLEFSEN 2019)

Ce travail a étudié l'effet de la préformation non supervisée dans les prédictions de RUL en utilisant une configuration semi-supervisée. Les expériences ont été réalisées sur l'ensemble de données C-MAPSS disponible publiquement. En addition, une approche GA a été proposée pour ajuster le nombre de différents hyper paramètres dans les architectures profondes.

Dans cette étude, un RBM a été utilisé comme étape initial de préformation non supervisée.

Le RBM est une technique d'apprentissage profond non supervisée plutôt ancienne. Des techniques d'apprentissage profond non supervisé plus puissantes sont disponibles comme le VAE [36,37] semble prometteur.

L'exactitude de ces approches dépend fortement de la qualité des étiquettes des données d'entraînement de défaillance. Le modèle utilisé dans cette étude est considéré comme une limitation majeure.

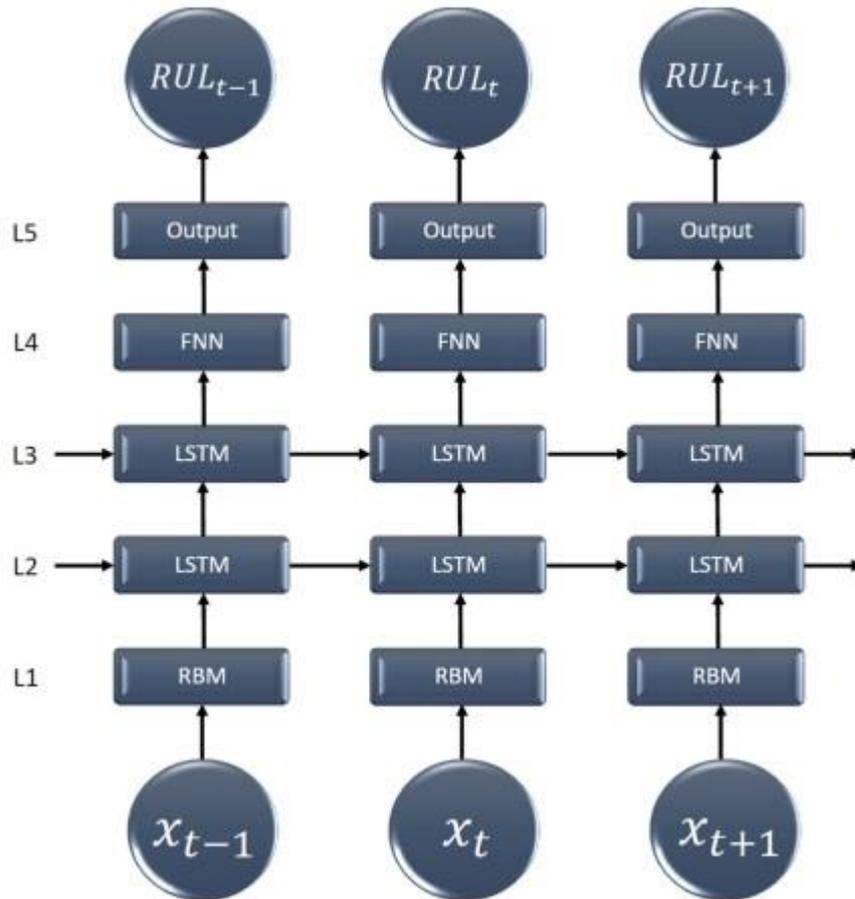


Figure 3-3 Structure d'architecture profonde semi-supervisée proposée

3.5 4^{ÈME} ÉTUDE : A LOCALLY ADAPTIVE ENSEMBLE APPROACH FOR DATA-DRIVEN PROGNOSTICS OF HETEROGENEOUS FLEETS (SAMER AL-DAHIDI, 2017) :

Ce travail propose une approche ensembliste basée sur l'utilisation de deux modèles pronostics basés sur les données : un modèle HDTFSSMM et un modèle FSB. Les prédictions de RUL fournies par les deux modèles sont agrégées à l'aide d'une stratégie pondérée localement qui attribue un poids et un biais en utilisant une mesure des performances locales des modèles

individuels de l'ensemble, c'est-à-dire la précision dans la prédiction de la RUL des motifs d'un ensemble de validation similaire a celui étudié.

L'approche proposée est capable de tirer parti de la disponibilité des données de surveillance de l'état collectées a partir de flottes hétérogènes et d'agréger les prédictions de RUL de manière adaptative.

Les principales contributions de ce travail sont :

L'application de la méthode de fusion locale développée dans Baraldi et al.⁴³ pour la tâche de pronostication de défaillance.

La proposition d'une nouvelle méthode pour sélectionner les motifs de l'ensemble de validation les plus similaires au motif de test.

Cette approche a été appliquée à une étude de cas portant sur une flotte hétérogène de condensateurs électrolytiques en aluminium.

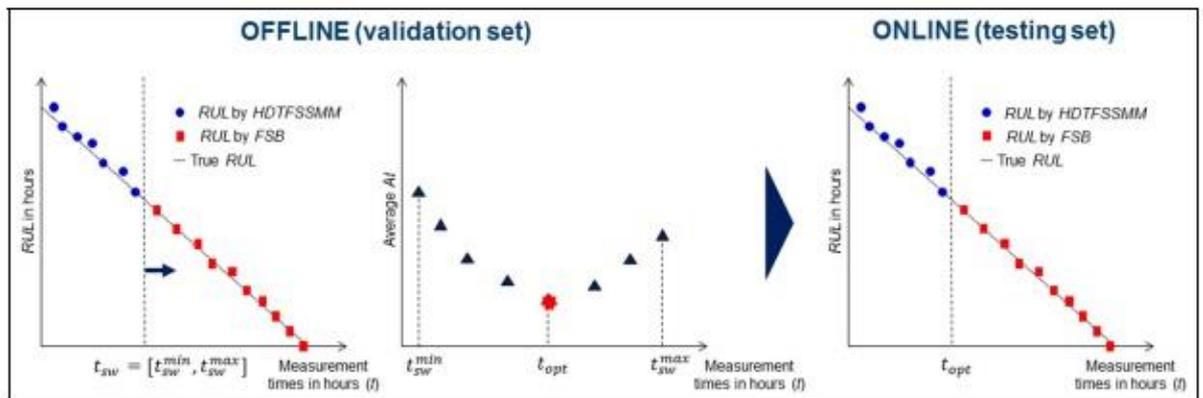


Figure 3-4 Organigramme de l'approche d'ensemble de commutation adaptative.

3.6 5^{ÈME} ÉTUDE : REMAINING USEFUL LIFE ESTIMATION IN PROGNOSTICS USING DEEP CONVOLUTION NEURAL NETWORKS (XIANG LI, 2018)

Dans cet article, une nouvelle méthode d'apprentissage profond pour la prévision est proposée, basée sur les réseaux neuronaux convolutés. La technique du dropout est utilisée pour atténuer le problème de surajustement. Des expériences sont menées sur le populaire jeu de données C-MAPSS afin de démontrer l'efficacité de la méthode proposée. L'objectif de la tâche est d'estimer avec précision la durée de vie restante des unités de moteurs aéronautiques. Grâce à la sélection des caractéristiques brutes, à la préparation des données et à la préparation des échantillons à l'aide de fenêtres temporelles, de bonnes performances prévisionnelles sont obtenues avec la méthode proposée, et une faible erreur entre la prédiction et la valeur réelle de la

durée de vie restante est obtenue pour les données de test. La durée de vie restante des unités de moteurs peut être bien prédite, en particulier pour la période tardive proche de la défaillance. La préparation des données est réalisée dans FD001, et cinq couches de convolution sont adoptées dans le réseau proposé. De plus, les résultats de prévision obtenus par la méthode proposée sont comparés aux résultats de pointe sur le même jeu de données dans la littérature. Le réseau proposé a démontré sa supériorité en termes de précision prévisionnelle et présente un fort potentiel pour les applications industrielles. De plus, il convient de noter que la méthode de prétraitement des données est utilisée dans cette étude.

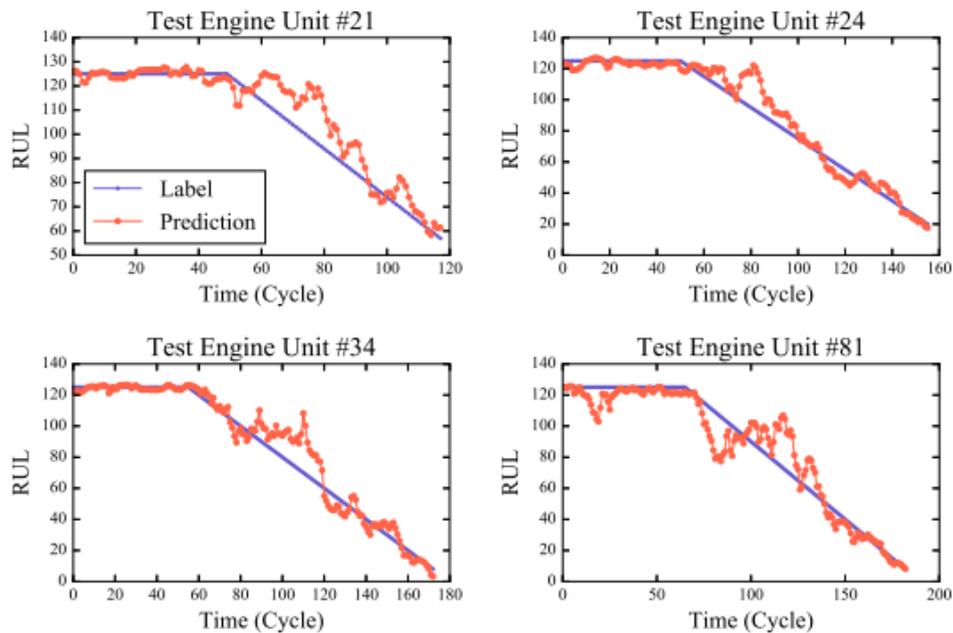


Figure 3-5 Quatre exemples de prédictions de la durée de vie restante (RUL) pour les unités de moteur de test dans FD001.

3.7 6^{ÈME} ÉTUDE : REMAINING USEFUL LIFE ESTIMATION OF TURBOFAN ENGINES USING ADAPTIVE FAULT DETECTION LEARNING (SOUALHI, 2022)

Dans cet article, une méthodologie de traitement des données pour la détection de défauts et la pronostique a été présentée. Cette méthodologie a utilisé les données de différents capteurs qui représentent divers scénarios de dégradation d'un système donné pour détecter les moments d'apparition des défauts et estimer leur durée de vie restante (RUL). En détail, les données enregistrées ont été traitées dans le domaine temporel en extrayant et en combinant des caractéristiques statistiques pour construire des indices de santé efficaces. Ces indices ont permis de séparer l'état sain de l'état défectueux en identifiant les moments d'apparition des défauts. L'utilisation du moment d'apparition des anomalies a facilité la tâche d'apprentissage du réseau

LSTM pour prédire avec précision la RUL du système. Les performances de la méthodologie proposée ont été mises en évidence à travers le jeu de données C-MPASS, montrant une amélioration de la précision de l'estimation de la RUL. Dans les travaux futurs, une fusion de la RUL estimée à partir de différents modèles de prédiction sera étudiée. Cette fusion permettra d'améliorer davantage la précision des prédictions pour une prise de décision efficace.

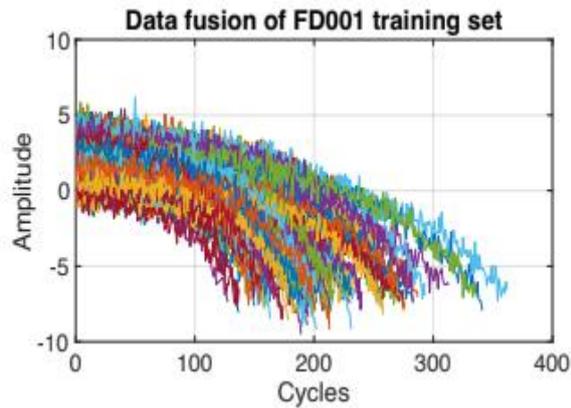


Figure 3-6 Données fusionnées globales des trajectoires totales

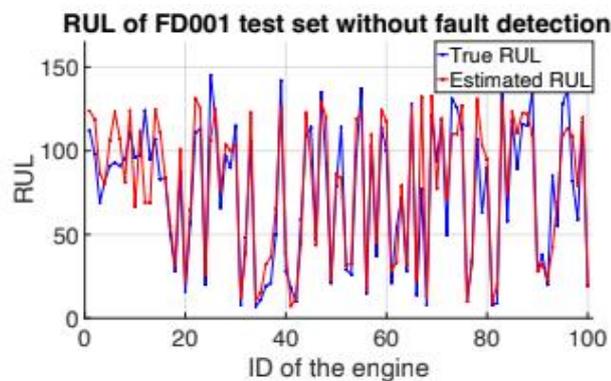


Figure 3-7 RUL estimé à l'aide d'un temps de prédiction unique

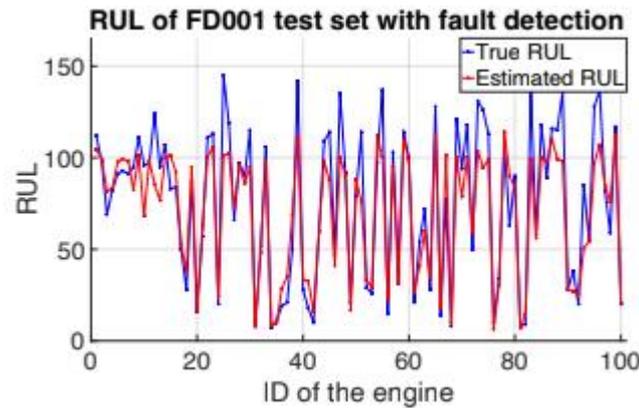


Figure 3-8 RUL estimé a l'aide d'un temps de prédiction adaptatif

3.8 7^{ÈME} ÉTUDE : ROTATING MACHINERY REMAINING USEFUL LIFE PREDICTION SCHEME USING DEEP-LEARNING-BASED HEALTH INDICATOR AND A NEW RVM (GANG ZHANG, 2021) :

Cet article propose un nouveau schéma de prédiction de la durée de vie utile restante (RUL) combinant l'apprentissage profond et une nouvelle méthode RVM. Tout d'abord, différents types de données de dégradation sont introduites dans le réseau d'apprentissage profond avec une structure hybride pour construire l'indicateur de santé. Ensuite, le nouveau modèle RVM composé de RVM et d'un modèle polynomial est utilisé pour prédire la RUL et calculer l'intervalle de confiance. Enfin, la méthode proposée est comparée à différentes méthodes de prédiction de la RUL pour vérifier son efficacité. Le réseau d'apprentissage profond proposé avec une structure hybride peut apprendre à partir de différents types de données de dégradation. La courbe de l'indicateur de santé construit présente une meilleure monotonie et une meilleure évolutivité que le réseau d'apprentissage profond à structure unique, tel que le CNN et le LSTM. Le RVM est largement utilisé dans la prédiction de la RUL. Les résultats finaux de prédiction de la RUL montrent que la méthode proposée peut améliorer la précision de prédiction et réduire l'intervalle de confiance.

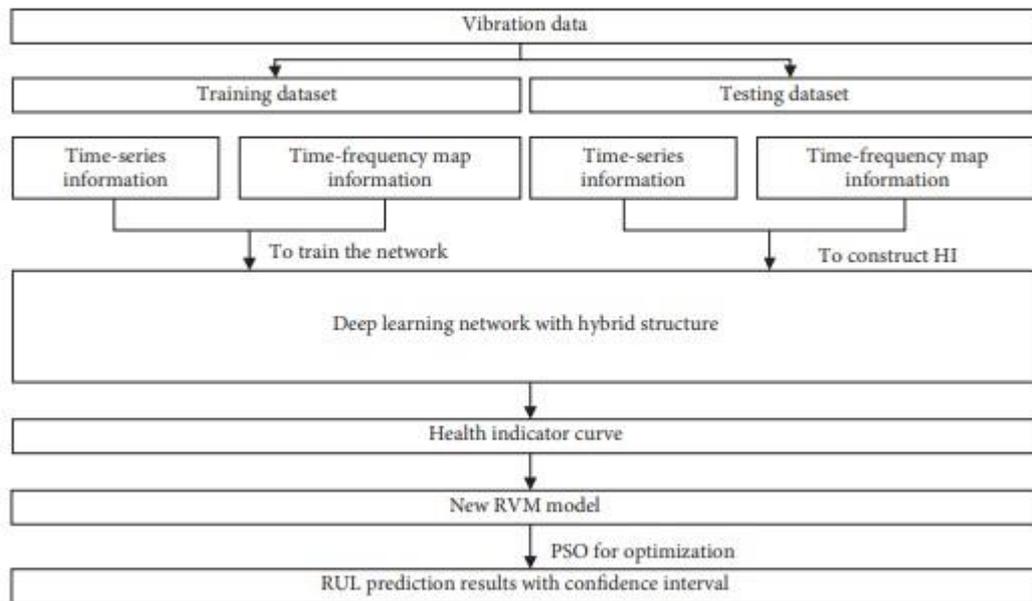


Figure 3-9 Schéma de l'RUL proposée

3.9 8^{ÈME} ÉTUDE : DATA-DRIVEN INTELLIGENT PREDICTIVE MAINTENANCE OF INDUSTRIAL ASSETS (OLGA FINK 2020) :

Les approches discutées dans ce travail surmontent certains des défis des applications pratiques de maintenance prédictive, notamment le manque de données étiquetées, la complexité et la haute dimensionnalité des signaux de surveillance de l'état, ainsi que la combinaison de la détection de défauts et du diagnostic de défauts. Cependant, les approches proposées imposent certaines exigences aux ensembles de données d'entraînement pour garantir leur applicabilité et leur robustesse aux applications réelles. L'une des exigences concerne la représentativité de l'ensemble de données d'entraînement, car les approches basées sur les données nécessitent d'apprendre les relations fonctionnelles à partir de données représentatives

Des échantillons. Une des limitations découlant de cette exigence est que les systèmes de maintenance prédictive ne peuvent pas être développés pour des systèmes nouvellement mis en service en raison du manque d'un ensemble de données d'entraînement représentatif.

Étant donné la rareté des données étiquetées pour les applications de maintenance basées sur l'état et prédictives, les approches non supervisées et semi-supervisées sont particulièrement prometteuses et doivent être davantage développées. Il y a eu plusieurs développements prometteurs dans d'autres domaines qui peuvent également être transférés aux applications de maintenance prédictive. Un autre défi consiste à rendre les caractéristiques apprises plus interprétables, en surmontant ainsi les limites de la black-box nature des approches basées sur l'apprentissage en profondeur.

3.10 9^{ÈME} ÉTUDE : DATA-DRIVEN APPROACH FOR FAULT PROGNOSTICS OF INDUSTRIAL SYSTEMS-FROM USING NO, INSUFFICIENT, TO MULTIPLE HISTORICAL DEGRADATION SEQUENCES (ABID , 2020) :

Dans cette étude, une approche ensembliste profonde est proposée, qui exploite la diversité de deux modèles d'apprentissage profond différents, nommés Réseau de Neurones Convolutif (CNN) et Réseau de Neurones à Mémoire à Court Terme (LSTM). L'architecture CNN peut extraire des informations pertinentes en appliquant plusieurs filtres de convolution sur les données brutes, tandis que LSTM est capable de capturer les informations temporelles dans les séries temporelles. L'approche ensembliste profonde proposée pour l'estimation de la durée de vie utile restante (RUL) est validée à l'aide de l'ensemble de données bien connu C-MAPSS et a obtenu des performances prometteuses par rapport aux résultats de pointe. Elle est également validée à l'aide d'un ensemble de données sur l'obstruction des filtres disponible dans le cadre du défi de données PHM Europe. Les résultats obtenus sur cet ensemble de données ont montré une précision de prédiction de RUL appropriée, qui devient plus précise lorsque la dégradation se rapproche de la défaillance. Étant donné que la fiabilité des prédictions est nécessaire pour les systèmes industriels critiques, l'approche ensembliste profonde proposée peut améliorer la fiabilité de la prédiction de RUL en fusionnant les prédictions de deux modèles différents. L'approche proposée a également montré sa capacité à capturer la variabilité des différents modes de fonctionnement lorsqu'elle est évaluée à l'aide de l'expérimentation C-MAPSS (système dynamique complexe avec différents modes de fonctionnement). Enfin, la méthode ensembliste profonde proposée pour l'estimation de la RUL a prouvé son efficacité, comme le démontrent les résultats obtenus, car elle a amélioré la précision de la prédiction de RUL.

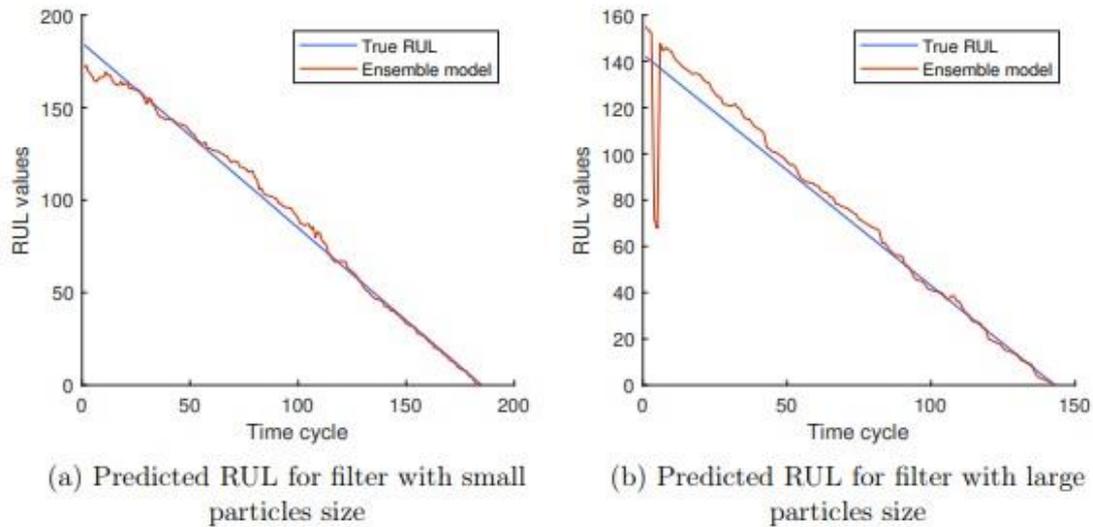
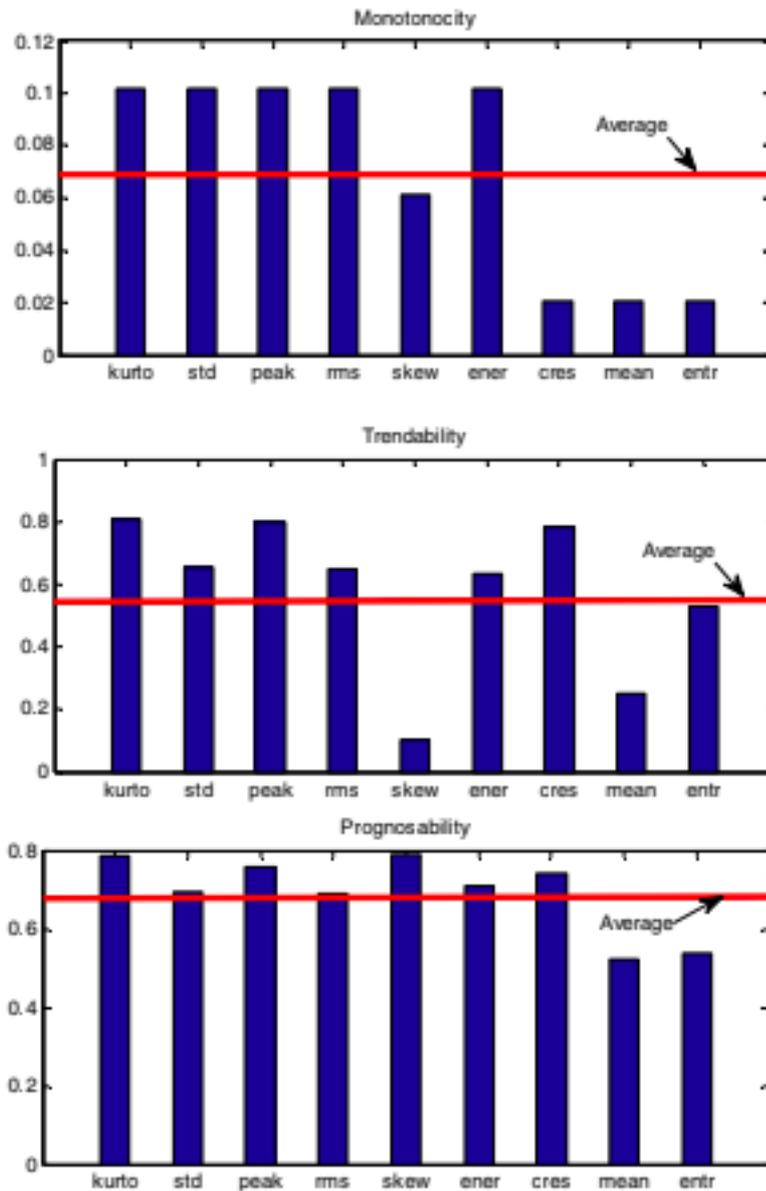


Figure 3-10 Exemples de prédiction de la durée de vie utile restante (RUL) pour le filtre avec de petites et grandes particules.

3.11 10^{ÈME} ÉTUDE : DIRECT WIND TURBINE DRIVETRAIN PROGNOSIS APPROACH USING ELMAN NEURAL NETWORK (SHARAF EDDINE KRAMTI,2018)

Dans cet étude, une nouvelle architecture ENN (Evolutionary Neural Network) a été proposée pour les tâches de pronostic. En considérant l'extraction et la sélection des caractéristiques dans le domaine temporel, six caractéristiques ont été utilisées en tant qu'entrées d'indicateur de santé pour l'ENN proposé. Une étude de cas du HSSB (Système de stockage hydraulique des éoliennes) d'une véritable éolienne commerciale a été prise en compte dans des conditions de fonctionnement réalistes. Sur la base de l'analyse des signaux de vibration, le réseau neuronal a obtenu de bons résultats de prédiction même avec une longue période de prédiction de 20 jours. En tant que travaux futurs, étant donné que les HSSB fonctionnent généralement dans des conditions environnementales difficiles et sont donc sujets à plusieurs types de défauts, l'étude du domaine fréquentiel et du domaine temps-fréquence sera envisagée. En effet, une comparaison avec d'autres types et architectures de réseaux neuronaux sera également abordée.



*Figure 3-11*Évaluation de caractéristiques statistiques dans le domaine temporel à l'aide de métriques de monotonie, de tendance et de pronosticabilité.

CONCLUSION

Pour conclure notre chapitre, nous avons appris des recherches précédentes la méthode et l'approche correctes à adopter pour atteindre notre objectif. La conclusion mise en place est tirée de la dixième étude qui aborde les quatre types de mesures dont nous avons besoin pour notre travail.

Chapitre 4: Mise en œuvre d'un algorithme en vue de la sélection des PHI

4.1 INTRODUCTION

Ce chapitre couvrira l'aspect programmation et le logiciel utilisé à des fins de pronostic (MATLAB). Notre travail se conclura par un test final et une validation du processus.

Le projet final consistera en une sélection automatique des données des capteurs via la PHM.

4.2 METHODOLOGIE DE MISE EN OUVRE PRONOSTIC GUIDE PAR LES DONNEES

La méthodologie de mise en œuvre du pronostic guidé par les données repose sur la collecte et l'intégration de données pertinentes. Une analyse statistique et d'intelligence artificielle est effectuée pour prédire l'évolution de la dégradation. Les modèles sont validés et intégrés dans un système de suivi en temps réel pour prédire la durée de vie résiduelle (RUL). Cette approche combine expertise en statistique et en intelligence artificielle pour une gestion proactive des dégradations

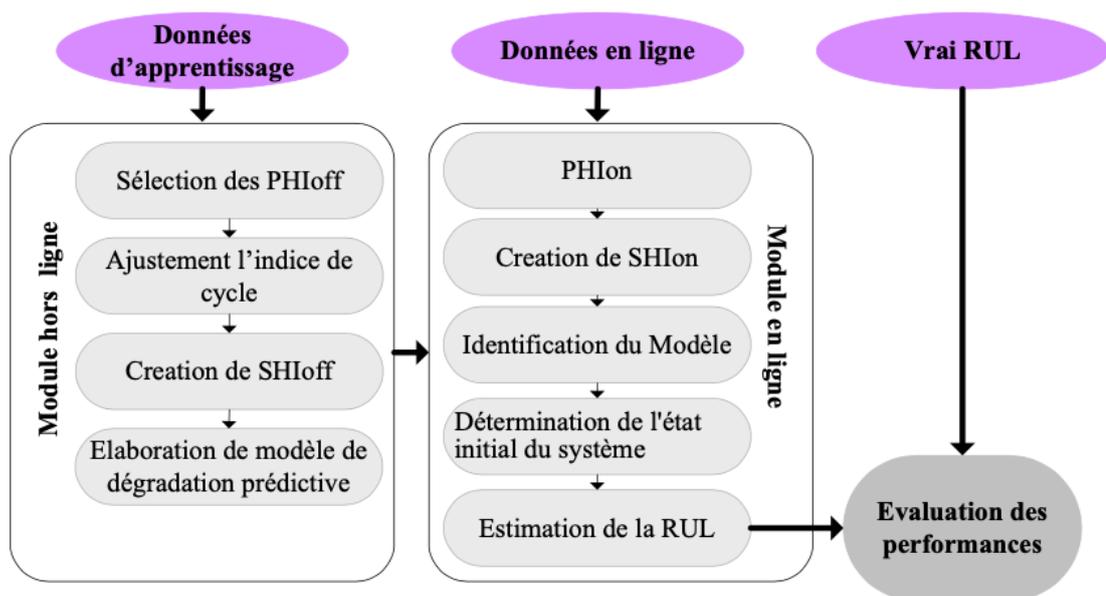


Figure 4-1 Méthodologie de mise en œuvre du pronostic guidée par les données (Motrani, 2022)

4.3 APPRENTISSAGE HORS LIGNE

La dégradation du système qui utilise des données d'apprentissage hors ligne se réfère à une détérioration des performances ou de la précision d'un système basé sur l'apprentissage automatique lorsqu'il est exposé à des données en temps réel ou à de nouvelles situations qui diffèrent des données utilisées pour son apprentissage initial. Lorsque le système est formé à l'aide

de données collectées précédemment et stockées hors ligne, il peut ne pas être en mesure de s'adapter efficacement aux changements dans les conditions, les distributions de données ou les exigences du problème réel. Cette dégradation peut se manifester par une baisse de la précision, une augmentation des erreurs ou une incapacité à généraliser correctement aux nouvelles données. Pour atténuer cette dégradation, il est souvent nécessaire de mettre à jour régulièrement les données d'apprentissage, de revoir et de réajuster les modèles ou d'explorer des approches d'apprentissage en ligne pour maintenir les performances du système dans des environnements en évolution.

4.4 PRESENTATION DES DONNEES

Les données expérimentales utilisées dans cette thèse ont été développées par le NASA Ames Research Center sur C-MAPSS (Commercial Modular Aero-Propulsion System Simulation). Ces données sont en libre accès depuis la première conférence internationale sur le Prognostic and Health Management (Challenge IEEE PHM) (Abhinav Saxena & Kai Goebel, 2008). Le challenge est toujours ouvert aux chercheurs afin de les encourager à développer leurs algorithmes.

4.5 TYPE DE MOTEURS

Un moteur turboréacteur est un type de moteur à réaction utilisé principalement dans l'aviation. Il est également connu sous le nom de moteur à réaction ou moteur à réaction pure. Le principe de base d'un turboréacteur repose sur la réaction de Newton : pour chaque action, il y a une réaction égale et opposée. Dans le cas d'un moteur turboréacteur, l'action est l'expulsion d'un flux d'air à grande vitesse vers l'arrière, ce qui génère une poussée vers l'avant.

Voici les principales composantes d'un moteur turboréacteur :

1. Compresseur : Il s'agit d'une série de rotors et de stators qui compriment l'air ambiant entrant. Le compresseur augmente la pression de l'air, ce qui permet une meilleure combustion et une augmentation de la poussée.
2. Chambre de combustion : Une fois comprimé, l'air est mélangé avec du carburant et enflammé dans la chambre de combustion. La combustion produit des gaz chauds à haute pression.
3. Turbine : Les gaz chauds et pressurisés provenant de la chambre de combustion passent à travers une turbine, qui est généralement située à l'arrière du moteur. L'énergie cinétique des gaz en expansion est utilisée pour alimenter le compresseur et les accessoires du moteur, tels que les systèmes électriques et hydrauliques.

4. Tuyère : Les gaz qui sortent de la turbine sont dirigés à travers une tuyère convergente-divergente. Cette tuyère accélère les gaz à une vitesse supersonique, créant une poussée vers l'avant selon le principe de la réaction de Newton.

Un moteur turboréacteur fonctionne en continu, aspirant de l'air ambiant, le comprimant, le mélangeant avec du carburant, le brûlant et expulsant les gaz brûlés à grande vitesse par la tuyère. Cette expulsion des gaz crée une force de poussée qui propulse l'aéronef vers l'avant. Les moteurs turboréacteurs sont principalement utilisés dans les avions de ligne, les avions de chasse et les avions militaires à réaction.

4.6 MATLAB ET PROGRAMATION

Le travail que nous avons effectué nécessite l'utilisation d'un logiciel de programmation, et nous avons choisi le logiciel MATLAB car il nous permet de faire de la simulation et de la classification des signaux à partir des données des capteurs que nous utilisons.

4.6.1 Matlab

C'est un logiciel de calcul numérique et de programmation développé par MathWorks. Il est largement utilisé dans les domaines de l'ingénierie, des sciences et des mathématiques, ainsi que dans d'autres disciplines connexes.

MATLAB offre un environnement de développement intégré (IDE) qui permet aux utilisateurs d'effectuer une variété de tâches, telles que l'analyse de données, la modélisation et la simulation, la conception de systèmes de contrôle, l'optimisation, la création de graphiques et la visualisation de données, entre autres. Il dispose également d'un langage de programmation propre à MATLAB, qui facilite l'écriture de scripts et de fonctions pour l'automatisation des tâches et l'implémentation d'algorithmes personnalisés. (MathWorks)

4.6.2 Données des capteurs traitées

On a des données qui contiennent 100 moteurs. Chaque moteur comporte plusieurs cycles pour lesquels nous calculons des valeurs. Par exemple le moteur 11 y a un total de 192 cycles et le moteur 2 en a 287. Il y a donc une variation entre chaque moteur.

Les données sont présentées sous forme de tableaux ce tableau comprend 26 colonnes

- La première colonne contient les moteurs,

	1
177	1
178	1
179	1
180	1
181	1

Figure 4-2 Colonne des moteurs

- La deuxième colonne contient les cycles

2
177
178
179
180
181

Figure 4-3 Colonne des cycles

- Les colonnes 3, 4 et 5 représentent les conditions

3	4	5
-0.0038	-3.0000e...	100
-1.0000e...	2.0000e-...	100
0.0023	-3.0000e...	100
-0.0024	0	100
-6.0000e...	5.0000e-...	100

Figure 4-4 Colonnes des conditions

- la sixième colonne à la vingt-sixième colonne, ce sont les capteurs. Chaque capteur correspond à une mesure spécifique telle que la température, la pression, etc.

6	7	8	25	26
518.6700	643.7900	1.6020e...	38.6300	23.1673
518.6700	643.3800	1.6053e...	38.6500	23.1770
518.6700	642.8600	1.5926e...	38.7700	23.1888
518.6700	643.5800	1.5999e...	38.8600	23.0070

Figure 4-5 Colonnes des capteurs

4.7 ETUDE DE CAS (L'ENSEMBLE C-MAPSS)

Dans cette étude de cas, nous nous intéressons au sous-ensemble FD_001 de l'ensemble C-MAPSS dataset (Motrani et al., 2021). Le fichier de données "train FD001.txt" est utilisé pour le module hors ligne tandis que le fichier "test FD001.txt" est utilisé pour le module en ligne. Chaque fichier contient les données de 100 turboréacteurs. Le but étant toujours de prédire leur nombre de cycles opérationnels restants avant leur défaillance. Dans cet ensemble de données, les vraies valeurs RULs pour les données de test sont données dans le fichier "RUL FD001.txt. (Motrani& Noureddine 2021)

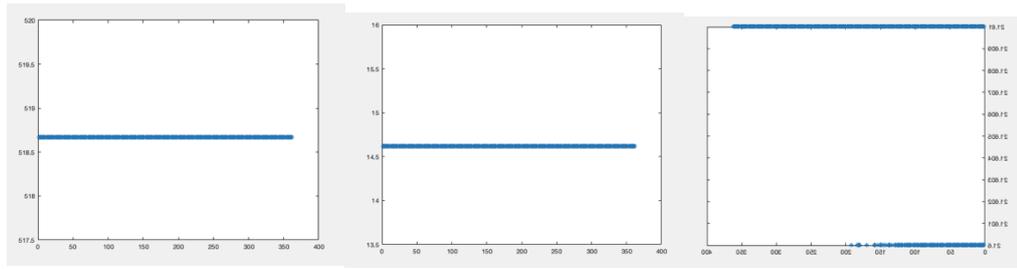
Travail précédent :

Le travail du Dr. Motrani portait sur la classification visuelle du modèle C-MAPSS à partir des graphes montrant les capteurs dégradants et non dégradants.

4.7.1 Sélection du PHIOff

On a 21 capteurs, certains d'entre eux présentent des signes de dégradation, tandis que d'autres ne montrent aucun signe de dégradation. Certains nécessitent une réparation ou un remplacement, tandis que d'autres semblent fonctionner normalement et ne posent aucun problème.

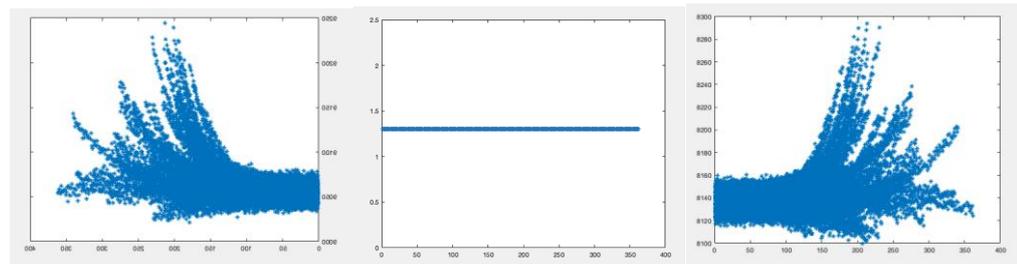
Les graphes ci-dessous montre les diverses dégradations parmi les 21 capteurs dans notre étude :



Capteur 6.

Capteur 10.

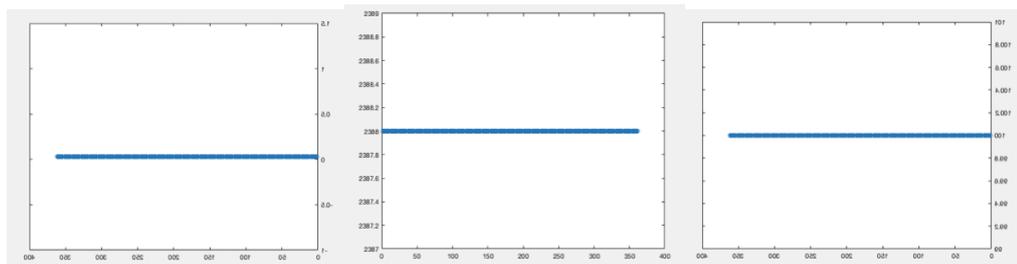
Capteur 11



Capteur 14.

Capteur 15.

Capteur 19

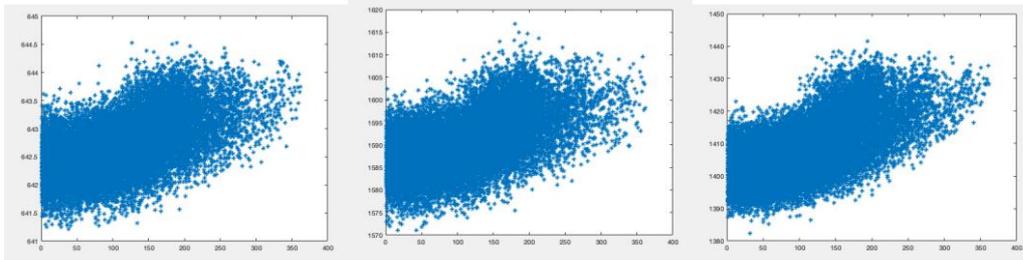


Capteur 21

Capteur 23

Capteur 24

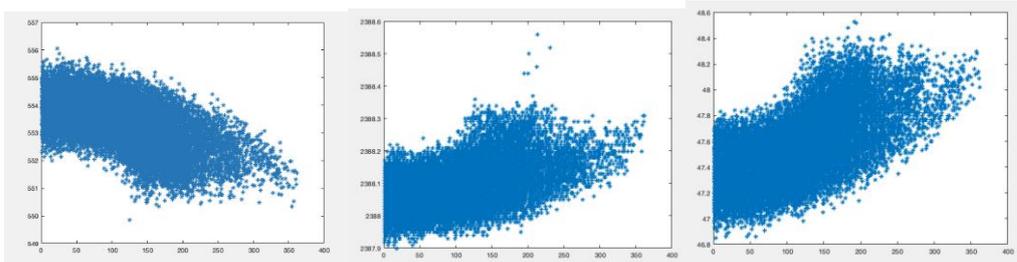
Figure 4-6 Signaux sans signification de dégradation



Capteur 7.

Capteur 8.

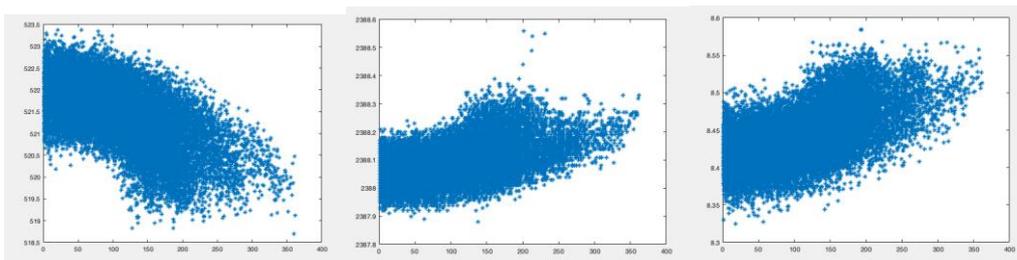
Capteur 9



Capteur 12.

Capteur 13.

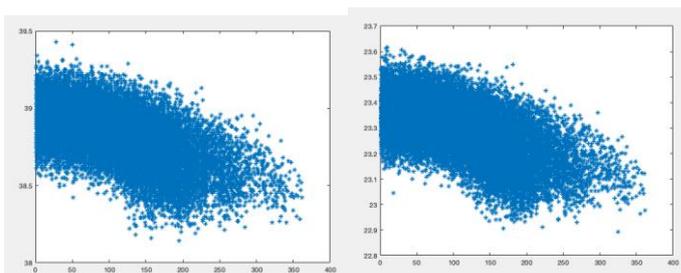
Capteur 16



Capteur 17.

Capteur 18.

Capteur 20



Capteur 25

Capteur 26

Figure 4-7 Signaux significatifs de dégradation

Notre tâche consistait à développer un programme qui crée une matrice pour effectuer une classification automatique et non pas visuelle.

4.7.2 Programmation

Pour effectuer la classification, nous utilisons les critères de monotonie, de trendabilité et de prévisibilité. Nous avons développé un algorithme basé sur leurs concepts mathématiques et nous avons ajouté une mesure appelée "suitability" qui est leur combinaison dans les trois aspects de la classification

Monotonie

La monotonie décrit le principal positif ou négatif tendance de l'indicateur. Il s'agit d'un indicateur important d'un processus de dégradation puisque la propagation du défaut de roulement est considéré comme un processus irréversible. La monotonie d'une population d'indicateurs est supposée par la moyenne différence entre le nombre de points positifs et négatifs croissance pour chaque point de temps de mesure. Considérant n nombre de points de temps de mesure, la monotonie peut être mathématiquement exprimée comme suit :

$$Monotonocity = \left| \frac{no\ of\ \left(\frac{d}{dt} < 0\right) - no\ of\ \left(\frac{d}{dt} > 0\right)}{n-1} \right| \quad (1)$$

La valeur de monotonie peut être comprise entre 0 et 1 : fortement les éléments monotones auront une monotonie =1 et pour les éléments non monotones une monotonie=0.

Trendabilité

La tendance est liée à la forme fonctionnelle d'un caractéristique extraite et sa corrélation avec le temps. C'est-à-dire comment le l'état d'un actif technique varie avec le temps. C'est un caractéristique constante aura une corrélation nulle avec le temps, où un fonction linéaire aura une forte corrélation. De manière similaire, la corrélation peut varier avec l'augmentation de la non-linéarité (c'est-à-dire qu'une caractéristique non linéaire entraînera une faible corrélation). Mathématiquement, la tendance peut être exprimée comme suit :

$$trendability = \frac{n(\sum\ time\ feature) - (\sum\ time)(\sum\ feature)}{\sqrt{[n\sum\ time^2 - (\sum\ time^2)] - [n\sum\ feature^2 - (\sum\ feature^2)]}} \quad (2)$$

La corrélation peut être positive, négative, parfaite ou non corrélation. Par conséquent, la tendance est toujours dans la plage [-1,1].

pronosticabilité

La pronosticabilité est obtenue comme l'écart-type de la mesure de dégradation divisées par l'intervalle entre la première et dernière mesure.

$$prognostability = \exp\left(-\frac{std(deg\ measures)}{mean(|final\ deg\ measures - first\ deg\ measures|)}\right) \quad (3)$$

Mesure composé

Une mesure composée est une combinaison de trois mesures que nous avons précédemment définies

$$Suitability = monotonicity + prognosability + trendability$$

Exécution de programme

Parti 1 de l'exécution :

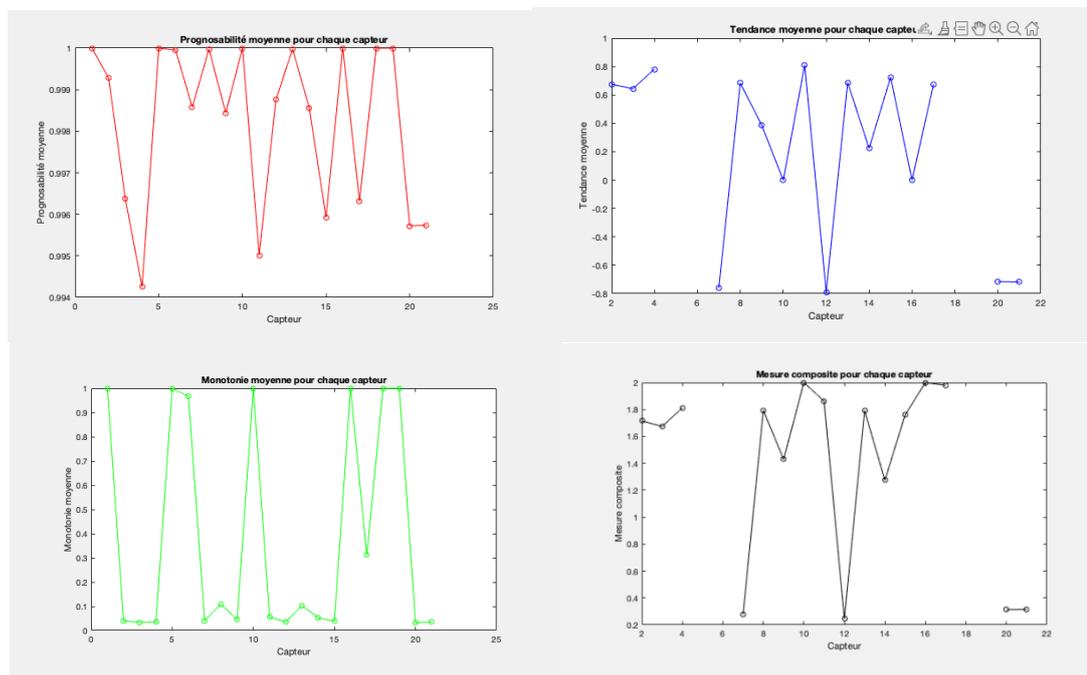


Figure 4-8 Graphe des quatre types de mesures

Partie 2 de l'exécution :

La deuxième partie de l'exécution consistera à créer le fichier dont nous avons mentionné le dans le programme sous nom « capteur ». Ce fichier contient un tableau avec les calculs des quatre mesures que nous avons définies.

	1 Sensor	2 Trend	3 Prog	4 mono	5 suit
1	1	0	1.0000	1	2
2	2	0.6753	0.9993	0.0405	1.7151
3	3	0.6440	0.9964	0.0340	1.6743
4	4	0.7816	0.9943	0.0359	1.8118
5	5	0	1.0000	1	2
6	6	0	1.0000	0.9666	2
7	7	-0.7615	0.9986	0.0413	0.2784
8	8	0.6835	1.0000	0.1093	1.7928
9	9	0.3860	0.9984	0.0451	1.4295
10	10	0	1.0000	1	2.0000
11	11	0.8106	0.9950	0.0565	1.8621
12	12	-0.7897	0.9988	0.0353	0.2444
13	13	0.6873	1.0000	0.1034	1.7907
14	14	0.2235	0.9986	0.0528	1.2748
15	15	0.7248	0.9959	0.0387	1.7595
16	16	0	1.0000	1	2.0000
17	17	0.6731	0.9963	0.3107	1.9801
18	18	0	1	1	2
19	19	0	1	1	2
20	20	-0.7141	0.9957	0.0319	0.3135
21	21	-0.7167	0.9957	0.0361	0.3152

Tableau 1 Calcul des quatre mesures

Classification des résultats de execution de programme par excel

Pour classer les résultats du fichier nommé "capteur", nous avons utilisé Excel pour ajouter manuellement l'état des capteurs dans une nouvelle colonne. Ensuite, nous avons utilisé à nouveau MATLAB pour effectuer la classification à l'aide de Classification Learner avec SVM.

Capture	trendability	Prognosabili	monotonicity	suitability	etat
1	0	0.999999999999999	1	2	stable,prog,fort-monotones
2	0.675275610664	0.99928006894025	0.040538296067	1.71509397567165	croissance,prog,non-monotones
3	0.643950348180	0.99636699759241	0.033964075066	1.67428142083891	croissance,prog,non-monotones
4	0.781613671111	0.99425365749534	0.035883196985	1.81175052559577	croissance,prog,non-monotones
5	0	1.00000000000000	1	2	stable,prog,fort-monotones
6	0	0.99995561931088	0.966611203336	1.96660000000000	stable,prog,fort-monotones
7	-0.76151439401	0.99857984496791	0.041295731774	0.27836118273107	décroissant,prog,non-monotones
8	0.683526241131	0.99997630089237	0.109284778425	1.79278732045314	croissance,prog,faible-monotones
9	0.385955485147	0.99843806597290	0.045090535364	1.42948408648492	croissance,prog,non-monotones
10	0	0.999999999999999	1	2.00000000000000	stable,prog,fort-monotones
11	0.810601216981	0.99501730223346	0.056495298252	1.86211381746802	croissance,prog,non-monotones
12	-0.78966224936	0.99875771865125	0.035337865765	0.24443333505550	décroissant,prog,non-monotones
13	0.687316124799	0.99997601864524	0.103426060465	1.79071820391063	croissance,prog,faible-monotones
14	0.223503861217	0.99855339018302	0.052767339376	1.27482459077713	croissance,prog,non-monotones
15	0.724844183243	0.99592564607012	0.038710674242	1.75948050355642	croissance,prog,non-monotones
16	0	1.00000000000000	1	2.00000000000000	stable,prog,fort-monotones
17	0.673122864781	0.99631653995509	0.310695116852	1.98013452158947	croissance,prog,faible-monotones
18	0	1	1	2	stable,prog,fort-monotones
19	0	1	1	2	stable,prog,fort-monotones
20	-0.71411980953	0.99572222490056	0.031900970833	0.31350338620287	décroissant,prog,non-monotones
21	-0.71670960928	0.99573514224917	0.036136687894	0.31516222086264	décroissant,prog,non-monotones

Tableau 2 état des mesures

On distingue quatre types d'état selon notre tableau :

- stable, prog, fort-monotones
- croissance, prog, non-monotones
- décroissant, prog, non-monotones
- croissance, prog, faible-monotones

Dans l'onglet APPS dans MATLAB, on va sélectionner classification learner.

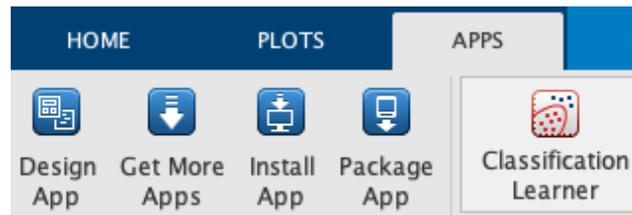


Figure 4-9 Onglet apps

Après on crée une nouvelle session par fichier comme montré ci-dessous

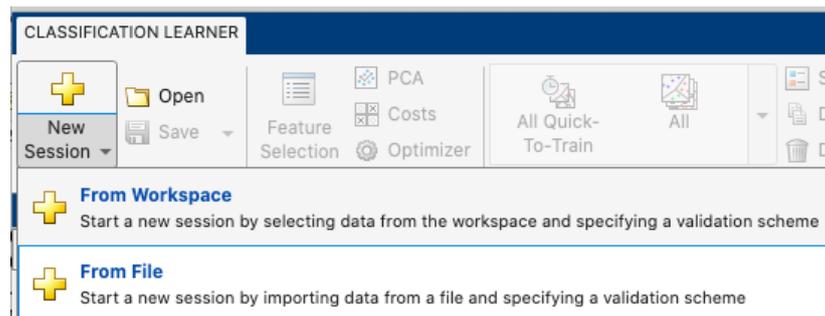


Figure 4-10 Classification learner onglet

Après la sélection du notre fichier Excel un tableau est générée automatiquement

	A capteur	B trend	C prog	D mono	E suit	F etat
	Number ▾	Text ▾	Text ▾	Text ▾	Text ▾	Categorical ▾
1	capteur	trend	prog	mono	suit	etat
2	1	0	1	1	2	stable,pro...
3	2	0.67528	0.99928	0.040538	1.7151	croissance...
4	3	0.64395	0.99637	0.033964	1.6743	croissance...
5	4	0.78161	0.99425	0.035883	1.8118	croissance...
6	5	0	1	1	2	stable,pro...
7	6	0	0.99996	0.96661	2	stable,pro...
8	7	-0.76151	0.99858	0.041296	0.27836	décroissa...
9	8	0.68353	0.99998	0.10928	1.7928	croissance...
10	9	0.38596	0.99844	0.045091	1.4295	croissance...
11	10	0	1	1	2	stable,pro...
12	11	0.8106	0.99502	0.056495	1.8621	croissance...
13	12	-0.78966	0.99876	0.035338	0.24443	décroissa...
14	13	0.68732	0.99998	0.10343	1.7907	croissance...
15	14	0.2235	0.99855	0.052767	1.2748	croissance...
16	15	0.72484	0.99593	0.038711	1.7595	croissance...
17	16	0	1	1	2	stable,pro...
18	17	0.67312	0.99632	0.3107	1.9801	croissance...
19	18	0	1	1	2	stable,pro...
20	19	0	1	1	2	stable,pro...
21	20	-0.71412	0.99572	0.031901	0.3135	décroissa...
22	21	-0.71671	0.99574	0.036137	0.31516	décroissa...

Tableau 3 Classification learner

4.8 RÉSULTATS ET DISCUSSIONS

4.8.1 Génération de matrice SVM finale pour classification des capteurs :

Notre but finale est de générer une matrice SVM qui classe les 21 capteurs utilisés selon leur état (4 états mentionnés précédents)

La matrice montre les nombres de capteurs appartenant à leur état approprié dans des carrés séparés.

Après avoir le tableau ci-dessus suivant la sélection du fichier Excel, on utilise la fonction All SVMs dans la barre d'utile de CLASSIFICATION LEARNER, ensuite, on click train ou bien exécuter, le Matlab donc va générer automatiquement une liste de précision des modèles, on choisit le plus précise pour la démonstration graphique de type 'Confusion Matrix'.

Les résultats sont comme dessous:

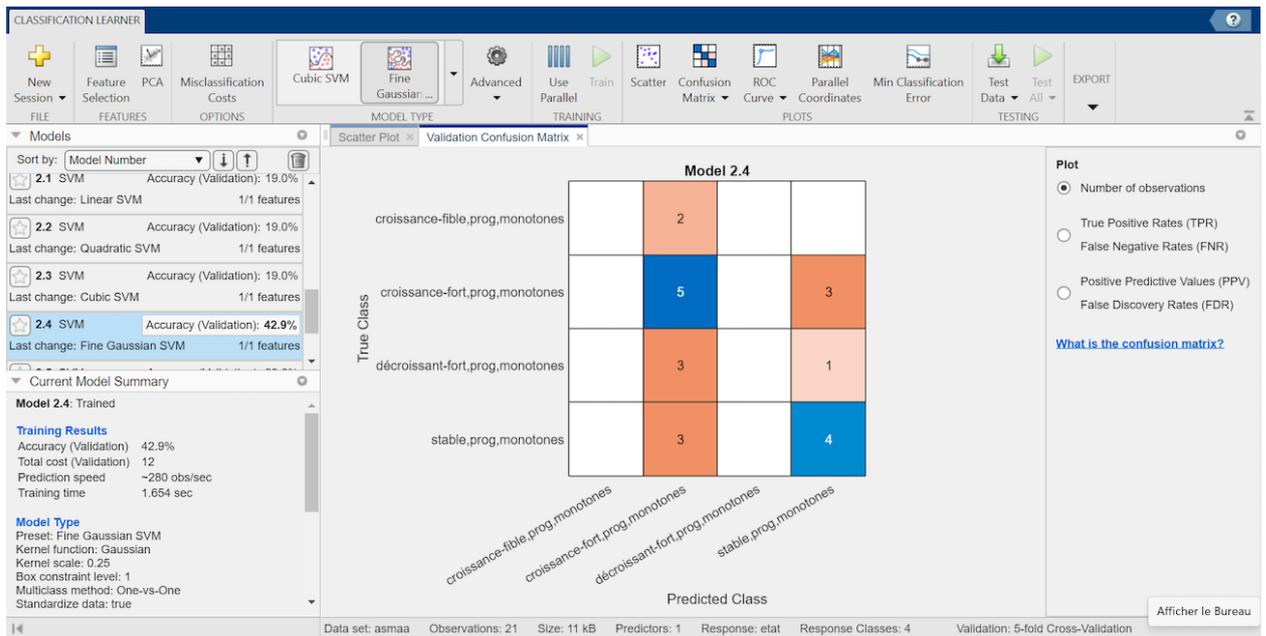


Figure 4-11 Classification par Matrice SVM

4.9 CONCLUSION

En conclusion, après avoir obtenu les résultats souhaités, ce chapitre démontre que nous avons mis en place une sélection automatique des données des capteurs via la PHM en utilisant une matrice SVM (Classification Learner).

Conclusion générale et perspectives

La maintenance et la maintenance prédictive, ainsi que la gestion de santé proactive (PHM, Prognostics and Health Management), jouent un rôle crucial dans la gestion efficace des équipements et des systèmes. En combinant ces approches, il est possible d'optimiser la disponibilité, la fiabilité et la durée de vie des actifs, tout en réduisant les coûts et en évitant les pannes imprévues.

En conclusion, cette étude a démontré l'efficacité de l'utilisation des applications Matlab pour la classification des données de capteur de C-Mapps. Les résultats obtenus ont confirmé que l'approche de classification basée sur Matlab offre une précision élevée dans la catégorisation des données collectées par les capteurs de C-MAPPS.

L'utilisation des outils et des fonctionnalités de Matlab a permis d'extraire des caractéristiques significatives à partir des données brutes et de les utiliser pour former des modèles de classification. Ces modèles ont été capables de distinguer avec précision les différentes classes ou catégories de données des capteurs de C-MAPPS.

Il convient de noter que l'efficacité de la classification dépend de la qualité et de la quantité des données disponibles, ainsi que du choix approprié des algorithmes et des paramètres utilisés dans le processus de classification. Des améliorations supplémentaires peuvent être apportées en explorant d'autres algorithmes de classification, en affinant les méthodes de prétraitement des données et en augmentant la taille de l'ensemble de données pour une meilleure généralisation des modèles de classification.

En conclusion, l'utilisation des applications Matlab pour la classification des données de capteur de C-MAPPS présente un potentiel prometteur et ouvre la voie

à des avancées supplémentaires dans le domaine industriel. Nous pouvons conclure que meilleure classification entraîne une meilleure prédiction.

Bibliographie

Abdo, A., El-Tawil, K., Kadry, S., Noura, H., & Ouladsine, M. (2010). Analytic prognostic model for a dynamic system. *International Review of Automatic Control*, 3, 568-577.

A. MOTRANI (2022), Contribution à la mise en œuvre de prognostic and health management (PHM) industriel, Thèse de doctorat, univervité d'Oran 2, Algerie

Muller, A. (2005). Contribution à la maintenance prévisionnelle des systèmes de production par la formalisation d'un processus de pronostic [Doctoral dissertation, Université Henri Poincaré - Nancy I, France].

Abid, K. (2020). *Data-driven Approach for Fault Prognostics of Industrial Systems-From Using No, Insufficient, to Multiple Historical Degradation Sequences* Ecole nationale supérieure Mines-Télécom Lille Douai].

Al-Dahidi, S., Di Maio, F., Baraldi, P., & Zio, E. (2017). A locally adaptive ensemble approach for data-driven prognostics of heterogeneous fleets. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, 231(4), 350-363.

Balakrishnan, S. (2013). *Industrial Maintenance Management*

D.L., A. J., & BANJEVIC., a. D. (2006). *A review on machinery diagnostics and prognostics implementing condition-based maintenance. Mechanical Systems and Signal Processing*, 20 :1483–1510, Oct .

Don Nyman, J. L. (2011). *Maintenance Planning, Coordination, and Scheduling. Industrial Press Inc.*

Ellefsen, A. L., Bjørlykhaug, E., Æsøy, V., Ushakov, S., & Zhang, H. (2019). Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture. *Reliability Engineering & System Safety*, 183, 240-251.

Fink, O. (2020). Data-driven intelligent predictive maintenance of industrial assets. *Women in Industrial and Systems Engineering: Key Advances and Perspectives on Emerging Topics*, 589-605.

Gouriveau, R., Medjaher, K., & Zerhouni, N. (2017). *Du concept de PHM à la maintenance prédictive 1: Surveillance et pronostic* (Vol. 3). ISTE Group.

Gulati, R., & Smith, R. (2009). *Maintenance and reliability best practices. Industrial Press Inc.*

Hinchi, A. Z., & Tkiouat, M. (2018). Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network. *Procedia Computer Science*, 127, 123-132.

ISO13381-1. (2004). Condition monitoring and diagnostics of machines - prognostics - Part1 : General guidelines. *Int. Standard, ISO*.

Luo, J., Namburu, M., Pattipati, K., Qiao, L., Kawamoto, M., & Chigusa, S. (2003). Model-based prognostic techniques. In AUTOTESTCON 2003. IEEE Systems Readiness Technology Conference, 6, 330-340. California, USA, September 2003.

Campbell, J. D. (2010). Maintenance Excellence: Optimizing Equipment Life-Cycle Decisions.

Kramti, S. E., Ali, J. B., Saidi, L., Sayadi, M., & Bechhoefer, E. (2018, April). Direct wind turbine drivetrain prognosis approach using Elman neural network. In *2018 5th International Conference on Control, Decision and Information Technologies (CoDIT)* (pp. 859-864). IEEE.

Li, X., Ding, Q., & Sun, J.-Q. (2018). Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering & System Safety*, 172, 1-11.

Lin, D., & Makis, V. (2003). Recursive filters for a partially observable system subject to random failure. *Advances in Applied Probability*, 35(1), 207-227.

DIEVART, M. (2010). Architectures de diagnostic et de pronostic distribuées de systèmes techniques complexes de grande dimension [Doctoral dissertation, Université de Toulouse, France]..

El Koujok, M. (2010). Contribution au pronostic industriel : intégration de la confiance à un modèle prédictif neuro-flou [Doctoral dissertation, L'U.F.R. Des Sciences et Techniques de l'Université de Franche-Comté, Besançon, France].

Motrani, A., Noureddine, R., & Noureddine, F. (2021). Performance evaluation of data-driven prognostic based on RVM-SBI technique. *Journal of the Serbian Society for Computational Mechanics*, 15(1), 37-50. <https://doi.org/10.24874/jssc.2021.15.01.03>

Nabila, B. S. (2016). Anticipation des dégradations en vue d'une maintenance efficace.

Nam-Ho Kim D. A. (2017), *Prognostics and Health Management of Engineering Systems: An Introduction*, 2017

NFEN13306. (2017). Maintenance—Maintenance Terminology. *BSI Standards Publication*.

Ordóñez, C., Lasheras, F. S., Roca-Pardiñas, J., & de Cos Juez, F. J. (2019). A hybrid ARIMA–SVM model for the study of the remaining useful life of aircraft engines. *Journal of Computational and Applied Mathematics*, 346, 184-191.

Palmer, R. (. (2013). *Maintenance Planning and Scheduling Handbook*.

Sandborn, P. A., & Wilkinson, C. (2007). A maintenance planning and business case development model for the application of prognostics and health management (PHM) to electronic systems. *Microelectronics reliability*, 47(12), 1889-1901.

Saxena, A., & Goebel, K. (2008). Turbofan engine degradation simulation data set. NASA Ames Prognostics Data repository, NASA Ames Research Center, Moffett Field. In.

Scanff, E., Feldman, K., Ghelam, S., Sandborn, P., Glade, M., & Foucher, B. (2007). Life cycle cost impact of using prognostic health management (PHM) for helicopter avionics. *Microelectronics reliability*, 47(12), 1857-1864.

Soualhi, M., Nguyen, K., Medjaher, K., & Zerhouni, N. (2022, October). Remaining useful life estimation of turbofan engines using adaptive fault detection learning. In *Annual Conference of the PHM Society* (Vol. 14, No. 1).

www.mathworks.com/products/matlab.html.

Zhang, G., Liang, W., She, B., & Tian, F. (2021). Rotating machinery remaining useful life prediction scheme using deep-learning-based health indicator and a new RVM. *Shock and Vibration*, 2021, 1-14.