



Université d'Oran 2  
Institut de Maintenance et de sécurité Industrielle

**THESE**

Pour l'obtention du diplôme de Doctorat « L.M.D »  
En Electromécanique

**Contribution à la mise en œuvre du Prognostic and Health  
Management (PHM) industriel**

Présentée et soutenue publiquement par :  
**MOTRANI Asmaa**

Devant le jury composé de :

<b>GUENDOZ Djilalia</b>	Professeur	Université d'Oran 2	Présidente
<b>NOUREDDINE Rachid</b>	Professeur	Université d'Oran 2	Directeur de thèse
<b>YAHIAOUI Reda</b>	MCA	Université d'Oran 2	Examineur
<b>FIZAZI Hadria</b>	Professeur	USTO-MB	Examineur
<b>HIRECHE Omar</b>	Professeur	ENPO-MA	Examineur

# Contribution à la mise en œuvre de Prognostic and Health Management (PHM) industriel

## Résumé :

Les exigences de sûreté de fonctionnement et de performance global impliquent l'amélioration de la disponibilité, de la fiabilité et de la sécurité des systèmes industrielles tout en réduisant leur coût de cycle de vie.

Une des solutions possibles est de faire évoluer la maintenance traditionnelle, réactive ou systématique, vers une maintenance proactive, conditionnelle ou prédictive. La principale spécificité de la maintenance prédictive réside dans la prédiction ou le pronostic future de la défaillance communément dénommée PHM (Prognostics and Health Management). Le but du pronostic industriel est de prédire l'état futur du système surveillé, et de donner, plus spécifiquement, une estimation de sa durée de vie utile restante (RUL). Parmi les approches utilisées, le pronostic guidé par les données est le plus prometteur lorsqu'il s'agit de traiter une multitude de données hétérogènes. L'objectif de cette thèse est de présenter la mise en œuvre d'une méthodologie de pronostic basée sur les données, où la durée de vie utile restante est déterminée par l'association de méthodes statistique et d'intelligence artificielle. Cette méthodologie proposée est basée sur l'algorithme RVM-SBL (Relevance Vector Machine-Sparse Bayesian Learning) pour construire le modèle de dégradation prédictif dans le module hors ligne, et sur l'algorithme RVM-SBI (Relevance Vector Machine- Sparse Bayesian Interpolation) pour la prédiction de la durée de vie utile restante dans le module en ligne. Les différentes étapes du cadre proposé sont décrites et mises en œuvre à travers deux études de cas. Les résultats obtenus ont été évalué et validé et permettent de confirmer l'acceptabilité de la méthodologie proposée.

**Mots clés :** Maintenance prédictive, pronostic et management de santé, approche guidée par les données, machine à vecteur de pertinence, interpolation basée sur similarité, durée de vie résiduelle.

## Contribution to the implementation of industrial Prognostic and Health Management (PHM)

### Abstract:

Operational safety and overall performance requirements involve improving the availability, reliability and safety of industrial systems while reducing their life cycle cost.

One of the possible solutions is to evolve traditional maintenance, reactive or systematic, towards proactive, conditional, or predictive maintenance. The main specificity of predictive maintenance lies in the future prediction of failure commonly referred to as PHM (Prognostics and Health Management). The purpose of the industrial prognostic is to predict the future state of the monitored system and to give, more specifically, an estimate of its remaining useful life (RUL). Among the approaches used, data-based prognostic is the most promising when dealing with a multitude of heterogeneous data. The objective of this thesis is to present the implementation of a data-driven prognostic methodology, where the remaining useful life is determined by the combination of statistical methods and artificial intelligence. This proposed methodology is based on RVM-SBL (Relevance Vector Machine- Sparse Bayesian Learning) algorithm to build the predictive degradation model in the offline part, and RVM-SBI (Relevance Vector Machine- Sparse Bayesian Interpolation) algorithm to estimate a remaining useful life in the online part. The different steps of the proposed framework are described and implemented through two case studies. The results obtained were evaluated and validated and confirm the acceptability of the proposed methodology.

**Key words:** Predictive Maintenance, Prognostic and Health Management, Data-driven approach, Relevance Vector Machine, Similarity Based Interpolation, Remaining Useful Life.

## المساهمة في تنفيذ التنبؤ والإدارة الصحية (PHM) الصناعية

### المخلص:

تتضمن متطلبات السلامة التشغيلية والأداء العام تحسين توافر وموثوقية وسلامة الأنظمة الصناعية مع تقليل تكلفة دورة حياتها. أحد الحلول الممكنة هو تطوير الصيانة التقليدية ، التفاعلية أو المنهجية ، نحو الصيانة الاستباقية أو المشروطة أو التنبؤية . تكمن الخصوصية الرئيسية للصيانة التنبؤية في التنبؤ المستقبلي بالفشل الذي يشار إليه عادةً باسم PHM ( التنبؤ وإدارة الصحة). الغرض من التكن الصناعي هو التنبؤ بالحالة المستقبلية للنظام الخاضع للمراقبة وإعطاء ، بشكل أكثر تحديداً ، تقديرًا لعمره الإنتاجي المتبقي (RUL). من بين الأساليب المستخدمة ، يعد التكن القائم على البيانات هو الأكثر واعدة عند التعامل مع العديد من البيانات غير المتجانسة. الهدف من هذه الأطروحة هو تقديم منهجية تنبؤية تعتمد على البيانات ، حيث يتم تحديد العمر الإنتاجي المتبقي من خلال مزيج من الأساليب الإحصائية والذكاء الاصطناعي. تعتمد هذه المنهجية على تقنية آلة المتجه الملاءمة (RVM-SBL) لبناء نموذج التدهور التنبؤي في الجزء غير المتصل ، وعلى تقنية الاستيفاء المستند إلى التشابه (RVM-SBI) لتقدير العمر النافع المتبقي في الجزء المتصل. يتم وصف وتنفيذ الخطوات المختلفة للإطار المقترح من خلال دراسة حالتين. تم تقييم النتائج التي تم الحصول عليها والتحقق من صحتها وتأكيد قبول المنهجية المقترحة.

**كلمات مفتاحية:** الصيانة الوقائية، التنبؤ وإدارة الصحة ، النهج القائم على البيانات ، آلة المتجهات ذات الصلة ، الاستيفاء القائم على التشابه، الحياة الإنتاجية المتبقية.

# Remerciements

Tous mes remerciements s'adressent tous d'abord au tout puissant ALLAH, d'avoir guidé mes pas vers le chemin du savoir.

Au moment où on croit en avoir fini avec la rédaction de la thèse, vient la partie qui n'est pas la plus simple à écrire...

Cette thèse a été pour moi une riche expérience qui ne peut s'achever sans remercier la personne qui m'a encadrée, aidée et soutenue durant les sept dernières années. Je tiens tout d'abord à remercier mon directeur de thèse, *Rachid NOUREDDINE*. Merci de m'avoir fait confiance et de m'avoir donné l'opportunité de travailler avec vous.

Je tiens à remercier les membres du jury qui ont gracieusement consacré leur temps à la révision de ce travail et qui m'ont également honoré par leur acceptation de l'évaluer, et surtout, de m'avoir donné l'opportunité de bénéficier de leur expertise pour progresser et développer mes perspectives.

J'adresse mes sincères remerciements à Madame *Halima BENAICHA*, pour ses conseils et encouragements durant la réalisation de ce projet de recherche.

Mes remerciements s'adressent aussi à Mr *Farid NOUREDDINE*, Professeur à L'ENIT de Toulouse, France pour son aide et sa contribution à ce projet de recherche.

Je voudrais finalement aussi remercier mes frère '*Abdelatif et Nadir*', mes sœurs '*Souad et Rofaida*' et mes grands-mères pour avoir cru en moi et m'avoir toujours soutenu et encouragé tout au long de mon parcours. Je remercie tout particulièrement mes très chers parents '*Noureddine et Nacéra*', pour leur irremplaçable et inconditionnel soutien. Sans eux, je n'aurais sans doute pas accompli les travaux présentés dans ce manuscrit.

Finalement, je remercie tous mes collègues ; les doctorants, qui m'ont reçu cordialement parmi eux dès le premier jour et m'ont aidé à m'adapter dans le milieu de la recherche scientifique.

Je dédie cette thèse à la mémoire de mon grand-père '*Abdelkader*' (*Que dieu lui pardonne et le bénisse*) qui aurait été si heureux de me voir terminer ce voyage.

# Sommaire

Remerciements.....	iii
Sommaire .....	iv
Liste des Figures .....	vii
Liste des Tableaux.....	ix
Liste des Abréviations.....	x
Nomenclature .....	xii
Introduction Générale.....	13
<b>Chapitre 1: Maintenance et PHM.....</b>	<b>15</b>
1.1 Introduction.....	16
1.2 Evolution de la maintenance vers le PHM.....	16
1.3 Types de maintenance.....	19
1.3.1 Maintenance corrective.....	20
Maintenance corrective différée.....	21
Maintenance corrective d'urgence .....	21
1.3.2 Maintenance améliorative.....	21
1.3.3 Maintenance préventive.....	22
Maintenance systématique .....	22
Maintenance conditionnelle .....	23
Maintenance prédictive .....	24
1.4 Prognostic and health management (PHM) .....	25
1.4.1 Applications de PHM .....	26
Centre IMS (Intelligent Maintenance Systems) .....	27
FEMTO-ST .....	27
Integrated Vehicle Health Management (IVHM) Centre.....	27
Prognostics Center of Excellence (PCoE).....	28
1.4.2 Avantages du PHM.....	28
1.4.3 Architectures de PHM .....	29
Processus de surveillance .....	29
Processus de pronostic .....	30
Processus d'aide à la décision .....	31
1.5 Conclusion .....	31
<b>Chapitre 2: Pronostics guidés par les données.....</b>	<b>32</b>
2.1 Introduction.....	33
2.2 Pronostic .....	33
2.2.1 Définition.....	34
2.2.2 Durée de vie résiduelle .....	35
2.2.3 Approches de pronostic .....	36
Approches basées sur l'expérience .....	38
Approche guidée par les données.....	38
Approche basée sur les modèles physiques.....	41
Approches hybride .....	42
2.2.4 Avantages et inconvénients des approches de pronostic .....	43
2.2.5 Méthodologie de choix d'une approche.....	44

2.3	Pronostic guidée par les données - Etat de l'art .....	46
2.3.1	Régression par processus gaussienne .....	46
2.3.2	Réseaux neuronaux artificiels (ANN « Artificial Neural Network ») .....	47
2.3.3	Machine à vecteur de support .....	50
2.3.4	Relevance Vector Machine .....	51
2.4	Conclusion .....	52
<b>Chapitre 3: Méthodologie théorique.....</b>		<b>54</b>
3.1	Introduction.....	55
3.2	Méthodologie de mise en œuvre du pronostic guidé par les données.....	55
3.2.1	Processus hors ligne.....	56
	Génération de l'indice de santé synthétisé.....	57
	Élaboration du modèle de dégradation prédictif .....	59
	Modèle RVM .....	60
3.2.2	Processus en ligne.....	63
	Identification du modèle IM.....	63
	Détermination de l'état initial du système .....	64
	Prédiction de la durée de vie utile restante.....	64
3.2.3	Mesures de performance.....	66
	Score .....	66
	Root Mean Square Error (RMSE).....	67
	Exactitude .....	67
3.3	Conclusion .....	68
<b>Chapitre 4: Méthodologie expérimentale.....</b>		<b>69</b>
4.1	Introduction.....	70
4.2	Présentation des données .....	70
4.2.1	Type de moteurs .....	70
4.2.2	Données traitées.....	71
4.3	Etude de cas 1 - PHM'08 challenge.....	75
4.3.1	Module hors ligne - Résultats et discussions .....	77
	Sélection du PHIOff.....	77
	Ajustement l'indice de cycle.....	77
	Création du <b>SHIOff</b> .....	78
	Élaboration du modèle de dégradation prédictif .....	79
4.3.2	Module en ligne - Résultats et discussions .....	80
	Création du SHIon .....	80
	Détermination de l'état initial du moteur.....	80
	Prédiction de la RUL.....	82
4.4	Etude de cas 2 – C-MAPSS .....	82
4.4.1	Module hors ligne – Résultats et discussions .....	83
	Sélection du PHIOff.....	83
	Création du <b>SHIOff</b> .....	83
	Élaboration du modèle de dégradation prédictif .....	84
4.4.2	Module en ligne -Résultats et discussions .....	85
	Création du SHIon .....	85
	Identification du modèle .....	86
	Détermination de l'état initial du turboréacteur.....	86
	Prédiction de la RUL.....	88
4.4.3	Évaluation des performances.....	89
	Mesures des performances.....	89
	Comparaison des performances .....	90
4.5	Conclusion .....	91

Conclusion générale .....	93
<b>Bibliographie.....</b>	<b>95</b>

# Liste des Figures

Figure 1.1 Exemple des systèmes nécessitant une maintenance préventive .....	17
Figure 1.2 Évolution des paradigmes de production et de maintenance .....	18
Figure 1.3 Formes de maintenance.....	20
Figure 1.4 Maintenance corrective .....	21
Figure 1.5 Maintenance systématique .....	23
Figure 1.6 Maintenance conditionnelle .....	24
Figure 1.7 Approche de maintenance prédictive .....	25
Figure 1.8 Architecture SIMP/OSA/CBM .....	30
Figure 2.1 Evolution unidirectionnelle d'un système sans maintenance ou action de réparation.....	33
Figure 2.2 Estimation de la RUL (Gouriveau et al., 2017) .....	36
Figure 2.3 Synthèse des classifications des approches de pronostic .....	39
Figure 2.4 Taxonomie des approches de pronostic .....	40
Figure 2.5 Approche de pronostic basée sur le modèle physique .....	42
Figure 2.6 Approche de pronostic hybride (série et parallèle)(Gouriveau et al., 2017)	43
Figure 2.7 Méthodologie de choix d'une approche de pronostic .....	45
Figure 2.8 Exemple d'un réseau de neurones artificiels.....	47
Figure 3.1 Méthodologie de mise en œuvre du pronostic guidée par les données .....	55
Figure 3.2 Illustration de construction d'un SHI.....	58
Figure 3.3 Les solutions possibles de la fonction $f(t)$ .....	60
Figure 3.4 Intervalle de performance .....	67
Figure 4.1 Moteurs turboréacteurs de C-MAPSS (Abhinav Saxena & Kai Goebel, 2008) .....	71
Figure 4.2 Effet des régimes opérationnels .....	76
Figure 4.3 Sélection des signaux - PHM'08.....	77
Figure 4.4 Indice de santé synthétisé « <i>SHIoff</i> » - PHM'08 .....	79
Figure 4.5 Modèle de dégradation prédictif – PHM'08 .....	80
Figure 4.6 Procédure de détermination du temps initial <b>T0</b> -PHM'08 .....	81
Figure 4.7 Temps initial <b>T0</b> et durée de vie restante projeté <b>RUL<sub>p</sub></b> – PHM'08 .....	82
Figure 4.8 Sélection des signaux - C-MAPSS.....	83
Figure 4.9 Indice de santé synthétisé « <i>SHIoff</i> » - C-MAPSS .....	84
Figure 4.10 Modèle de dégradation prédictif – C-MAPSS .....	85
Figure 4.11 Identification du modèle .....	86

Figure 4.12 Procédure de détermination du temps initial <b>T0</b> -C-MAPSS .....	87
Figure 4.13 Temps initial <b>T0</b> et durée de vie restante projeté <b>RULp</b> – C-MAPSS ...	88
Figure 4.14 Interpolation par similarité.....	89



# Liste des Tableaux

Tableau 2.1 Les approches de pronostic.....	43
Tableau 4.1 Descriptions des ensembles de données C-MAPSS et PHM'08 .....	72
Tableau 4.2 Descriptions des réglages opérationnels.....	73
Tableau 4.3 Descriptions des mesures des capteurs.....	74
Tableau 4.4 Descriptions des données des capteurs.....	75
Tableau 4.5 Régimes opérationnels.....	76
Tableau 4.6 Evaluation de performance.....	90
Tableau 4.7 Comparaison des résultats de score.....	90

# Liste des Abréviations

<b>ARD</b>	Automatic Relevance Determination
<b>ANN</b>	Artificial Neural Network
<b>ARIMA</b>	auto-regressive integrated moving average
<b>AUKF</b>	Adaptive Unscented Kalman Filter
<b>CBM</b>	Condition Based Maintenance
<b>C-MAPSS</b>	Commercial Modular Aero-Propulsion System Simulation
<b>CNN</b>	Convolutional Neural Network
<b>DCNN</b>	Deep Convolutional Neural Network
<b>Deep LSTM</b>	Deep Long Short-term memory
<b>DOD</b>	Département de la défense des États-Unis
<b>DWNN</b>	Dynamic Wavelet neural networks
<b>EM</b>	Expectation Maximization
<b>EOF</b>	End Of Life
<b>EOL</b>	End Of Life
<b>FAMET-ST</b>	Franche-Comté Electronique Mécanique Thermique et Optique – Sciences et Technologies
<b>GPR</b>	Gaussian Process Regression
<b>HI</b>	Health index
<b>HUMS</b>	Health and Usage Monitoring System
<b>HPC</b>	High Pressure Compressor
<b>HPT</b>	High Pressure Turbine
<b>IHM</b>	Interface Homme-Machine
<b>IM</b>	Identification de modèle
<b>IMS</b>	Intelligent Maintenance Systems
<b>ISO</b>	International Standardization Organisation
<b>IVHM</b>	Integrated Vehicle Health Management Centre
<b>KNN</b>	k-nearest neighbors
<b>LPC</b>	Low Pressure Compressor
<b>LPT</b>	Low Pressure Turbine
<b>LSTM</b>	Long Short Term Memory
<b>MLP</b>	Multi layer perceptron
<b>MS-DCNM</b>	Multi-Scale Deep Convolutional Neural Network
<b>M.Sc</b>	Master of science
<b>N1</b>	Turbine axis
<b>N2</b>	Turbine shaft
<b>NASA</b>	National Aeronautics and Space Administration

<b>NF</b>	Neural-Fuzzy
<b>NF EN</b>	Normes Françaises, Norme Européenne
<b>NFS</b>	National Science Foundation
<b>NNs</b>	Classic sigmoïde neurones
<b>OSA/CBM</b>	Open System Architecture for Condition-Based Maintenance
<b>PCoE</b>	Prognostics Center of Excellence
<b>PHI</b>	Physics Health Index
<b>PHI off</b>	Offline Physics Health Index
<b>PHIon</b>	Online physics health index
<b>PHM</b>	Prognostics and Health Management
<b>PM</b>	Predictive maintenance
<b>PSO</b>	Particle Swarm Optimization
<b>RM</b>	Reactive maintenance
<b>RMSE</b>	Root Mean Squar Error
<b>RNN</b>	Recurrent Neural Network
<b>RUL</b>	remaining useful life
<b>RVM</b>	Relevance vector machine
<b>SBI</b>	Similarity Based Interpolation
<b>SBL</b>	Sparse Bayesian Learning
<b>SHI</b>	Sythetic Health Index
<b>SIMP</b>	Système Intégré de Maintenance Prévisionnelle
<b>SM</b>	Scheduled Maintenance
<b>SVM</b>	Support Vector Machine
<b>SVR</b>	Support Vector Regression
<b>TCMN</b>	Temporal Conventional Memory Network
<b>TRA</b>	Throttle Resolver Angle
<b>UCRC</b>	University Cooperative Research Center
<b>WNN</b>	Wavelet Neural Network

# Nomenclature

<b>ai, bi</b>	Hyperparamètres
<b>C</b>	Cycle de fonctionnement
<b>Cf</b>	Cycle défectueux
<b>Cadj</b>	Cycle ajusté
<b>E</b>	Exactitude
<b>ft</b>	Foot
<b><math>h_{IM}</math></b>	Modèle de dégradation identifié
<b>lb</b>	Pound
<b>lbm/s</b>	Pound mass/second
<b><math>L_{off}</math></b>	Durée de vie hors ligne
<b><math>L_{on}</math></b>	Durée de vie en ligne
<b>pps</b>	Pints per second
<b>Psi</b>	Pound/square inch
<b>Psia</b>	Pound/square inch [absolute]
<b>rpm</b>	Revolutions per minute
<b>RULp</b>	projected remaining useful life
<b>°R</b>	Degree Rankine
<b><math>Q_0</math></b>	Matrice d'état défectueux
<b><math>Q_1</math></b>	Matrice d'état sain
<b><math>Q_{off}</math></b>	Matrice des données hors ligne
<b><math>Q_{on}</math></b>	Matrice des données hors ligne
<b>S</b>	Score
<b><math>SHI_{on}</math></b>	Online sythetise heath index
<b><math>SHI_{off}</math></b>	Offline sythetise heath index
<b><math>t_c</math></b>	Temps courant
<b><math>t_{EOL}</math></b>	Temps de fin de vie
<b>T</b>	Matrice de transformation
<b><math>T_0</math></b>	Etat initial du système
<b><math>W_i</math></b>	Poids de la similarité (W)
<b><math>\alpha</math></b>	Hyperparamètre
<b><math>\beta</math></b>	Variance
<b><math>\varepsilon</math></b>	Mesure du bruit
<b><math>\Phi</math></b>	Fonction noyaux
<b><math>\omega</math></b>	Poids

# Introduction Générale

« Mieux vaut prévenir que guérir » est également vrai dans l'industrie. Les systèmes industriels ont vécu un changement radical dans leur fonctionnalité, ils deviennent de plus en plus complexes ; subir une panne va peser lourdement économiquement sur l'appareil productif et sa maintenance associée.

L'une des performances majeures de l'industrie est l'allongement de la durée de vie des systèmes complexes. Avec ces besoins croissants d'efficacité et les coûts de maintenance croissants dus à des pannes non-maîtrisées, de nombreuses industries utilisent la Maintenance Prédictive (PM : Predictive Maintenance) pour apporter des solutions permettant de prédire la défaillance d'un composant ou un système en amont, réduisant ainsi le temps d'arrêt du système en planifiant l'intervention de maintenance. Le Prognostic and Health Management (PHM) est une discipline d'ingénierie qui vise à maintenir le comportement et le fonctionnement du système tout en garantissant le succès, la sécurité et l'efficacité de la mission. Certaines techniques de pronostic utilisées et acceptées dans le monde entier sont devenues très répandues dans de nombreuses industries au cours des dernières décennies. Ces techniques sont pertinentes dans des environnements où la prédiction d'une défaillance, la prévention et l'atténuation de ses conséquences augmentent les profits et renforcent la sécurité des installations concernées. Par contre de nouvelles techniques de pronostic s'appuyant notamment sur l'intelligence artificielle sont en pleine évolution et tentent à s'imposer dans des systèmes réels multivariés. C'est dans ce cadre que s'inscrit le travail de cette thèse.

Le pronostic est la partie la plus critique du processus « PHM » et est actuellement reconnu comme un élément clé des stratégies de maintenance, car l'estimation de la durée de vie utile restante (RUL : Remaining Useful Life) est essentielle. Il fait l'objet d'un intérêt croissant depuis plusieurs décennies et plusieurs méthodes ont été développées, testées et améliorées au fil des avancées technologiques. Dans le processus de conception, de fabrication et d'exploitation du système complexe, le sous-système et ses modules peuvent acquérir de nombreuses informations de connaissance, notamment les caractéristiques de comportement du système, le modèle empirique, l'historique des tests et les données de surveillance des capteurs. Sur la base de ces informations de connaissance, il existe différentes approches de pronostic de défaillance en conséquence.

Selon plusieurs études, quatre approches essentielles de pronostic sont détaillées dans cette thèse : l'approche physique, l'approche basée sur les données, l'approche hybride et l'approche basé sur l'expérience. Le cadre du travail de cette thèse est orienté vers l'approche guidée par les données. Le pronostic guidé par les données est basé sur l'exploitation d'indicateurs physiques ou synthétiques de la dégradation dont l'évolution future est déterminée soit par une méthode d'analyse de tendance soit par une méthode d'apprentissage.

La structure de cette thèse se décline en 4 chapitres :

➤ Le chapitre 1 présente l'évolution de la maintenance vers le PHM. Ce chapitre décrit les différentes stratégies de maintenance. Les applications et les avantages du PHM sont ensuite introduits, avec les différentes architectures proposées par les chercheurs qui sont détaillé à la fin du chapitre.

➤ Le chapitre 2 focalise sur l'étape centrale du PHM qui est le pronostic. Dans un premier temps, les définitions du pronostic et de la durée de vie résiduelle (RUL) sont introduites, les différentes approches de pronostic ainsi que leurs avantages et inconvénients sont présentés. Une méthodologie de choix d'une approche est proposée à la fin de la première partie. Les méthodes de pronostic guidées par les données sont décrites et détaillées dans l'état de l'art effectué dans la deuxième partie.

➤ Le chapitre 3 vise à décrire la méthodologie de l'approche de pronostic guidées par les données, proposée. Cette approche est basée sur la technique RVM-SBL (Relevance Vector Machine-Sparse Bayesian Learning) dans le module hors ligne et RVM-SBI (Relevance Vector Machine-Sparse Bayesian Interpolation) dans le module en ligne. Les méthodes d'évaluation des performances des algorithmes et les métriques y afférant, assurant une prédiction acceptable des RULs, sont aussi présentées.

➤ Le chapitre 4 est consacré à la mise en œuvre de la méthodologie proposée et sa validation. Pour étudier l'efficacité de la méthodologie, deux études de cas utilisant des données industrielles, relatives aux dégradations de turboréacteurs, sont implémentées et présentées. Les résultats obtenus sont d'une part évaluée à travers trois métriques, et d'autre part comparés et discutée avec d'autres résultats provenant de publications récentes.

# Chapitre 1: Maintenance et PHM

---

1.1	<u>Introduction</u> .....	16
1.2	<u>Evolution de la maintenance vers le PHM</u> .....	16
1.3	<u>Types de maintenance</u> .....	19
1.3.1	<u>Maintenance corrective</u> .....	20
	<u>Maintenance corrective différée</u> .....	21
	<u>Maintenance corrective d'urgence</u> .....	21
1.3.2	<u>Maintenance améliorative</u> .....	21
1.3.3	<u>Maintenance préventive</u> .....	22
	<u>Maintenance systématique</u> .....	22
	<u>Maintenance conditionnelle</u> .....	23
	<u>Maintenance prédictive</u> .....	24
1.4	<u>Prognostic and health management (PHM)</u> .....	25
1.4.1	<u>Applications de PHM</u> .....	26
	<u>Centre IMS (Intelligent Maintenance Systems)</u> .....	27
	<u>FEMTO-ST</u> .....	27
	<u>Integrated Vehicle Health Management (IVHM) Centre</u> .....	27
	<u>Prognostics Center of Excellence (PCoE)</u> .....	28
1.4.2	<u>Avantages du PHM</u> .....	28
1.4.3	<u>Architectures de PHM</u> .....	29
	<u>Processus de surveillance</u> .....	29
	<u>Processus de pronostic</u> .....	30
	<u>Processus d'aide à la décision</u> .....	31
1.5	<u>Conclusion</u> .....	31

## 1.1 INTRODUCTION

Les services de maintenance rapides et efficaces sont nécessaires dans l'industrie pour garantir la mise en œuvre des systèmes de production efficaces par les entreprises. Ce besoin est particulièrement évident pour les systèmes dont les défaillances ne peuvent être tolérées pour des raisons économiques ou de sécurité. Par conséquent, il est souhaitable que leurs mécanismes soient anticipés pour programmer les actions de maintenance appropriées. Pour cela, l'une des solutions candidate est l'utilisation du concept de PHM (Prognostics and Health Management).

Le but de ce chapitre est de présenter un aperçu complet liant la maintenance au concept de PHM. L'évolution de la maintenance vers le PHM est présentée dans la section suivante. Dans la deuxième section, nous présentons les approches de maintenance les plus courantes, en soulignant les avantages et les inconvénients de ces différentes méthodes en termes de coûts et de temps d'arrêt global de la machine. Dans la troisième section, le concept de Prognostic and Health Management est défini, les applications, les avantages et différentes architectures de PHM sont décrits. Finalement, on termine par une conclusion.

## 1.2 EVOLUTION DE LA MAINTENANCE VERS LE PHM

Certains biens, par exemple une machine à laver, peuvent être utilisés en continu jusqu'à ce qu'ils perdent leurs fonctions. Presque aucune maintenance n'est appliquée au préalable, car la défaillance d'un tel bien n'entraînera généralement pas de perte économique significative ou de conséquence fatale ce qui implique qu'aucune action de réparation ou de maintenance n'est requise avant l'apparition d'une défaillance. Cette maintenance est appelée *maintenance corrective, réactive* ou *non planifier*. Le problème lié à cette approche est l'apparition de temps d'arrêt non-programmés à des moments peu pratiques, ce qui peut empêcher la continuité dans la production. Les temps d'arrêt imprévus ont des conséquences plus graves sur des applications telles que les moteurs d'avion. Et aussi la possibilité de violations graves de la sécurité et de dommages potentiellement importants aux équipements de fabrication et aux produits en cours de fabrication ou d'assemblage.

La maintenance n'est effectuée que plus tard pour "corriger" une défaillance. Certains biens, par exemple un véhicule, doivent être entretenus régulièrement en fonction du temps ou du kilométrage pour s'assurer qu'ils sont en bon état ; sans un entretien prioritaire appropriée, un véhicule peut être dangereux. Ce type de maintenance est appelé "**maintenance préventive**", ce qui implique que la maintenance est appliquée régulièrement à un équipement pour aider à prévenir



les défaillances inattendues (Kothamasu et al., 2006). La maintenance préventive est actuellement la maintenance la plus courante qui est effectuée sur les appareils, les machines, les avions, les équipements et les installations (Figure 1.1).



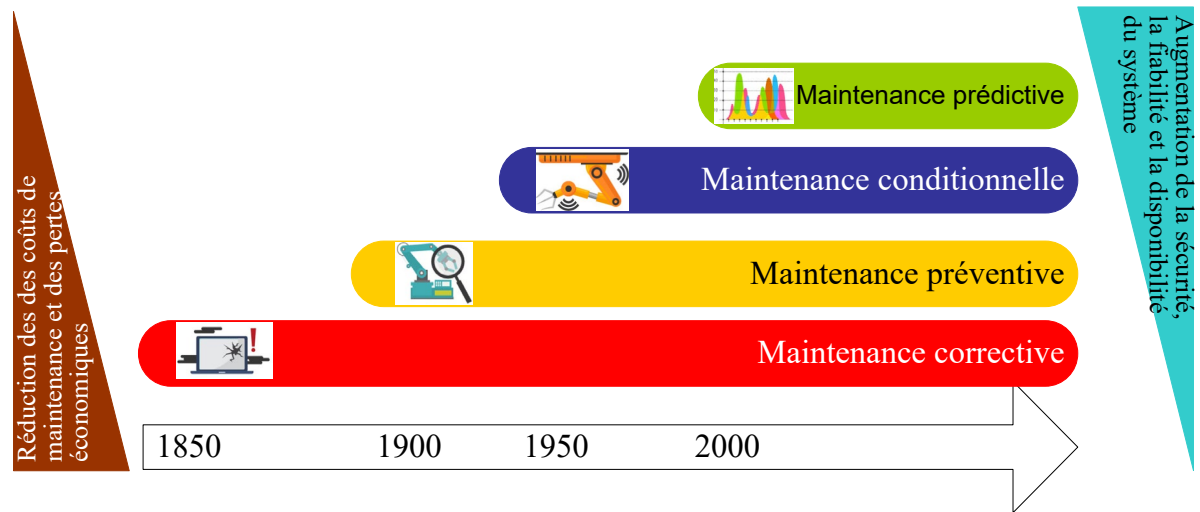
*Figure 1.1 Exemple des systèmes nécessitant une maintenance préventive*

La maintenance engendre des coûts et nécessite parfois un arrêt de l'actif ou une interruption de l'opération qui cause des désagréments dans notre vie ou notre production. Jusqu'à ce point, on peut se poser la question suivante :

***Est-il possible de minimiser la maintenance et de garantir en même temps un bon état de santé d'un système ?***

La réponse à cette question est : oui, c'est tout à fait possible si l'on adopte la "maintenance conditionnelle" ou "CBM" (Condition Based Maintenance). La maintenance conditionnelle n'est pas un concept nouveau qui remonte aux années 1950 (Takata et al., 2004). Elle signifie que l'état de santé d'un bien est étroitement surveillé en temps réel et que la maintenance n'est assurée que lorsqu'un défaut est détecté ou que l'état de santé d'un bien se dégrade jusqu'à un certain seuil. Si l'on prend l'exemple d'un véhicule, l'huile moteur est régulièrement changée pour garantir le bon état de santé du moteur de la voiture ; cependant, il arrive que l'huile moteur usagée soit encore en bon état parce que le véhicule n'a pas beaucoup roulé au cours des derniers mois ; si une

technologie CBM capable de surveiller l'état de l'huile moteur était disponible, le service d'entretien du moteur serait probablement prolongé de trois mois ou plus, ce qui permettrait d'économiser à la fois le coût du service et l'environnement en minimisant les changements d'huile.



**Figure 1.2** Évolution des paradigmes de production et de maintenance

La maintenance conditionnelle offre la possibilité de minimiser la maintenance tout en maximisant la disponibilité et la sécurité d'un bien. Dans le cadre de la maintenance conditionnelle, un défi consiste à estimer avec précision l'état (c'est-à-dire l'état de santé) d'un bien, de préférence en temps réel. L'état fait ici référence à l'état de santé passé, actuel ou futur du bien. Avant les années 1990, la maintenance conditionnelle s'appuyait principalement sur l'état de santé passé et actuel d'un bien. Cependant, à partir des années 1990, des recherches approfondies ont commencé à envisager d'inclure l'état de santé futur prédit d'un bien dans la maintenance conditionnelle et cette "maintenance conditionnelle" assistée par la prédiction (ou centrée sur la prédiction) est appelée spécialement "maintenance prédictive" (PM). La maintenance prédictive s'appuie non seulement sur les conditions de santé passées et actuelles d'un bien qui est surveillé, mais aussi sur les conditions de santé futures qui sont pronostiquées. Les technologies et/ou applications associées à la maintenance prédictive sont généralement appelées "Prognostic and health management", en français : "gestion des pronostics et de la santé" ou, par abréviation, "PHM".

S'il est déjà difficile de surveiller l'état de santé passé et actuel d'un bien, il est encore plus difficile de pronostiquer l'état de santé futur d'un bien. Le PHM est une méthodologie d'évaluation de la fiabilité d'un système afin de prévoir et d'atténuer les défaillances (Sun et al., 2010). La discipline PHM est apparue, il y a environ une dizaine d'années et depuis cette notion se développe pour offrir des solutions afin de réduire les coûts de production tout en étant capable d'améliorer

la disponibilité et la fiabilité des systèmes complexes. Le pronostic permet également de réduire le délai d'approvisionnement et de planification de la maintenance tout en favorisant la possibilité d'une logistique autonome (Banks & Merenich, 2007). L'amélioration de l'efficacité de la maintenance grâce au PHM à l'échelle du système pourrait réduire les coûts de main-d'œuvre liés à la maintenance de plus de 10 % par rapport aux coûts de la maintenance réactive (corrective)(Barajas & Srinivasa, 2008). En résumé, le PHM vise à anticiper les défaillances industrielles, maîtriser l'arrêt des machines, augmenter leur durée de vie, diminuer les stocks de pièces de rechange.

### 1.3 TYPES DE MAINTENANCE

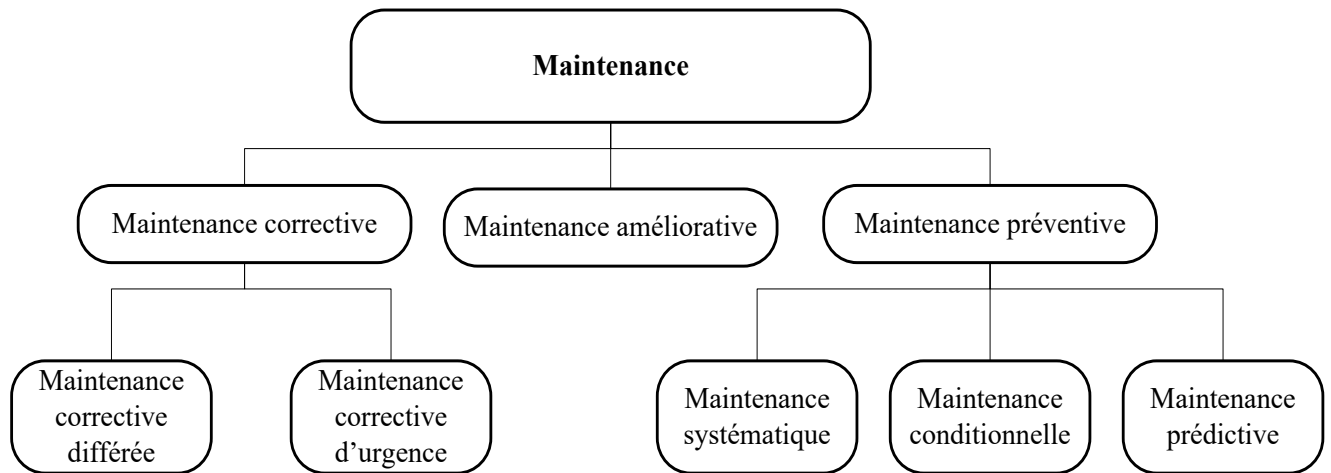
Le terme « maintenance », forgé sur les racines latines manus et tenere, est apparu dans la langue française au XIIe siècle. L'étymologiste Wace a trouvé la forme main-teneur (celui qui soutient), utilisée en 1169 : c'est une forme archaïque de « mainteneur » (Monchy & Vernier, 2000).

Selon la norme européenne NF EN 13306 (2017) la maintenance est définie comme :

*« 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 » (NFEN13306, 2017).*

La maintenance doit permettre d'améliorer la fiabilité, la sécurité et la qualité des équipements du système industriel tout en respectant des critères économiques liés au coût de mise en œuvre. Son objectif est de préserver les fonctions du système et du produit tout au long de leur cycle de vie. La définition de la maintenance distingue deux cas de Figure dans la maintenance d'un système. Le terme *maintenir* fait référence aux activités de maintenance mises en œuvre sur un système en fonctionnement afin d'éviter qu'il ne tombe en panne alors que *rétablir* implique les activités de « correction » qui sont menées une fois que le système a déjà échoué.

Le choix d'une stratégie de maintenance efficace est crucial pour réduire les coûts et minimiser les temps d'arrêt de la machine. L'adoption d'une stratégie de maintenance particulière dépend principalement des besoins et des caractéristiques de la ligne de production de l'entreprise. En effet, chaque politique de maintenance introduit des avantages et des inconvénients impactant directement les coûts dans différentes modalités. Dans cette partie, nous identifions trois approches distinctes de la maintenance, à savoir : la maintenance réactive ou corrective (RM), la maintenance améliorative et la maintenance préventive, Figure 1.3.



*Figure 1.3 Formes de maintenance*


### 1.3.1 Maintenance corrective

La maintenance corrective ou réactive est basée sur une action a posteriori, c'est-à-dire après l'apparition d'un défaut (Par exemple : remplacement des batteries complètement déchargées, réparation d'un pneu crevé, remplacement de la courroie de distribution usée). 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 ».*

Donc elle consiste à réparer ou à remplacer un composant de la machine uniquement lorsqu'il tombe en panne et qu'il ne peut plus fonctionner. L'avantage immédiat de cette approche est que la quantité de main-d'œuvre de maintenance et les dépenses liées au fonctionnement des machines sont minimisées (Swanson, 2001). De plus, comme les machines sont actives jusqu'à ce qu'elles tombent en panne, leur temps d'utilisation est maximisé. D'un autre côté, cette approche est risquée à bien des égards. D'abord et avant tout, il est potentiellement dangereux du point de vue de la sécurité. Attendre qu'une machine atteigne son niveau de stress maximal peut entraîner des pannes catastrophiques. De plus, ce type de pannes entraîne généralement des coûts plus importants et nécessite un temps de réparation important. Par conséquent, en adoptant cette stratégie de maintenance, on peut s'attendre à des coûts considérables résultant à la fois des réparations de pannes graves et des temps d'arrêt non planifiés relativement importants des machines. Ce type de maintenance est généralement adapté pour les équipements pour lesquels (Gouriveau et al., 2017) :

- les conséquences de la panne ne sont pas critiques ;
- la réparation est facile et ne nécessite pas beaucoup de temps ;
- les coûts d'investissements sont faibles.



**Figure 1.4** Maintenance corrective

La maintenance corrective se distingue en :

#### ***Maintenance corrective différée***

Maintenance corrective qui n'est pas exécutée immédiatement après la détection d'une panne, mais est retardée en accord avec des règles de maintenance données.

#### ***Maintenance corrective d'urgence***

Maintenance corrective qui est exécutée sans délai après détection d'une panne afin d'éviter des conséquences inacceptables.

### **1.3.2 Maintenance améliorative**

« Ensemble des mesures techniques, administratives et de gestion, destinée à améliorer la sûreté de fonctionnement d'un bien sans changer sa fonction requise », selon la norme NF EN 13306(2017) (NFEN13306, 2017).

L'amélioration des biens d'équipement consiste à procéder à des modifications des changements des transformations sur un matériel correspondant à la maintenance améliorative. Cependant, pour toute maintenance d'amélioration, une étude économique sérieuse s'impose pour s'assurer de la rentabilité du projet. L'amélioration à apporter peut avoir comme objectif l'augmentation des performances de production du matériel, l'augmentation de la fiabilité, c'est-à-dire diminuer les fréquences d'intervention, l'amélioration de la maintenance (amélioration de l'accessibilité des sous-systèmes et des éléments à haute risque de défaillance), la standardisation de certains éléments pour avoir une politique plus cohérente et améliorer les actions de maintenance, l'augmentation de la sécurité du personnel.

### 1.3.3 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. La norme européenne (NFEN13306, 2017) définit la maintenance préventive ainsi :

*« Maintenance destinée à évaluer et/ou atténuer la dégradation et réduire la probabilité de défaillance d'un bien ».*

L'un des principaux défis de la maintenance préventive en contexte opérationnel est que les scénarios industriels d'analyse des données ne permettent pas de suivre le passé, les comportements anormaux ou les opérations de maintenance effectuées afin de corriger ou de prévenir un comportement défectueux. Par conséquent, 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 systématique***


La maintenance systématique (SM) est généralement exécutée sur une période prédéfinie ou alternativement sur la base d'indicateurs objectifs définis et créés par une analyse de fiabilité et sur la base des données empiriques passées (Smith et al., 1997). Ce type d'entretien est dit prédéterminé. Remplacement de la batterie après un laps de temps spécifique, remplacement de la courroie de distribution après un nombre spécifique de kilomètres...etc, tout cela pourrait être répertorié comme exemple de maintenance prédéterminée ou maintenance systématique. La norme NF 13306 (2017) la définit comme :

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

Les intervalles de temps ou le nombre d'unités d'usage peuvent être établis d'après la connaissance des mécanismes de défaillance du bien.

La maintenance systématique est basée sur des interventions de maintenance effectuées à intervalles de temps réguliers. L'objectif est de minimiser la probabilité de pannes et d'éviter ainsi des temps d'arrêt imprévus coûteux en effectuant des activités de maintenance même lorsque la machine fonctionne encore dans des conditions normales. La SM s'appuie fortement sur un calendrier significatif qui doit être adapté aux propriétés spécifiques de l'équipement. En particulier, les experts doivent fournir une évaluation détaillée du comportement de défaillance des machines et de leurs composants afin de maximiser le niveau de précision sur la prédiction du

prochain temps de défaillance. Le principal avantage de maintenance systématiques qu'il réduit considérablement les temps d'arrêt imprévus. De plus, les coûts de réparation sont généralement moins élevés que ceux rencontrés en maintenance corrective, puisque, désormais, les machines ne sont pas autorisées à fonctionner jusqu'à leur point de rupture. En revanche, une approche SM présente le risque concret de réaliser plusieurs interventions de maintenance relativement coûteuses même lorsque l'équipement fonctionne encore correctement. Aussi, S'en tenir à un modèle de dégradation fixe d'une certaine machine peut conduire les opérateurs de maintenance à manquer des anomalies causées par des facteurs externes ou des dysfonctionnements internes qui font que le modèle de dégradation de la machine s'écarte de sa tendance prévue.



*Figure 1.5 Maintenance systématique*


### ***Maintenance conditionnelle***

La maintenance conditionnelle est définie comme maintenance préventive qui inclut l'évaluation des conditions physiques, l'analyse et les éventuelles actions de maintenance qui en découlent. L'évaluation des conditions peut être effectuée par observation réalisée par l'opérateur et/ou inspection et/ou essais et/ou surveillance de l'état des paramètres système, etc. et menée selon un programme, sur demande ou en continu (Noureddine et al., 2013).

La maintenance conditionnelle vise à anticiper une opération de maintenance basée sur la mise en évidence de dégradations et d'écarts par rapport à un comportement normal supposé d'un actif. L'équipement est surveillé avec plusieurs capteurs qui sont censés acquérir des données pertinentes (par exemple, les vibrations, la température, etc.) sur la durée de vie de l'équipement. Elle vise la détection d'anomalies dans le fonctionnement des machines industrielles : la découverte de changements dans leurs caractéristiques préfigure à court terme d'une défaillance à venir.

Une approche CBM interviendrait sur le système immédiatement après l'heure de détection. Cette méthode pourrait conduire au remplacement ou à la réparation d'un composant de

l'équipement même s'il aurait pu continuer sa routine normale pendant une période plus longue sans affecter les autres parties de la machine. De plus, intervenir immédiatement après la détection du défaut peut entraîner l'arrêt du cycle de travail des machines à un stade inopportun du point de vue de l'efficacité de la production.



**Figure 1.6** Maintenance conditionnelle

### **Maintenance prédictive**

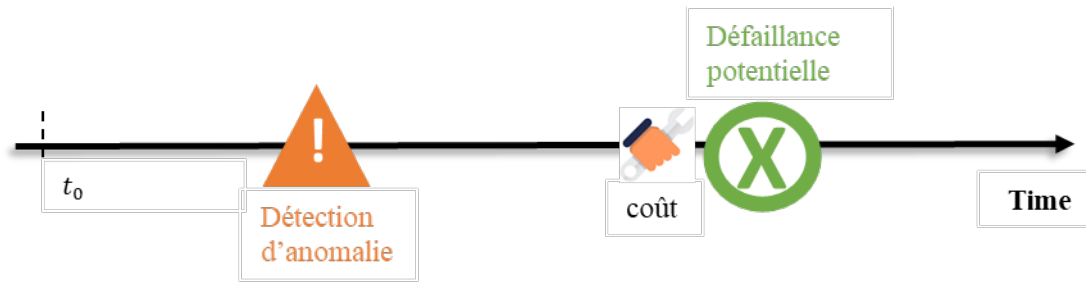
Selon la norme EN 13306(2017), la maintenance prédictive ou prévisionnelle est définie comme :

« Maintenance conditionnelle exécutée suite à une prévision obtenue grâce à une analyse répétée ou à des caractéristiques connues et à une évaluation des paramètres significatifs de la dégradation du bien » (NFEN13306, 2017).

L'idée sous-jacente est de projeter l'état actuel du bien dans le futur, afin d'estimer le temps de fonctionnement avant la défaillance.

La maintenance prédictive est une sous-classe de la maintenance conditionnelle. Elle utilise une variété d'approches et de techniques d'apprentissage automatique pour étudier les données récentes et historiques et pour apprendre des modèles de pronostic qui devraient faire des prédictions précises sur l'état futur d'une machine ou d'un équipement. La maintenance préventive est subordonnée à l'analyse de l'évolution surveillée de paramètres significatifs de la dégradation du bien. Elle essaie de prédire la durée de vie utile d'un composant à un certain pas de temps afin d'indiquer le moment dans le futur où la maintenance doit être effectuée. Cette dernière approche entraîne inévitablement des coûts de maintenance inférieurs par rapport à la CBM, puisque chaque composant peut être pleinement exploité sans sacrifier la sécurité et l'efficacité (Fink, 2020) (Figure 1.7).





**Figure 1.7** Approche de maintenance prédictive

La principale différence entre la CBM et la PM est que les algorithmes PM traitent du problème de la prédiction de la durée de vie utile restante (RUL) d'un composant industriel avant qu'une défaillance complète ne se produise et que la machine ne soit plus en mesure de fonctionner (Medjaher et al., 2012). Par conséquent, les principaux catalyseurs des stratégies PM sont des algorithmes capables de prévoir efficacement l'état futur d'une machine, c'est-à-dire de fournir des informations pronostiques sur sa RUL.

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 pour Prognostic Health Management (Sandborn & Wilkinson, 2007; Scanff et al., 2007).

#### 1.4 PROGNOSTIC AND HEALTH MANAGEMENT (PHM)

Le PHM constitue actuellement une préoccupation des chercheurs et des industriels. Ils s'interrogent sur la stratégie de PHM qui peut aider à atteindre les conditions de maintenance prédictive. En effet, le PHM peut améliorer la maintenance en évaluant l'état de santé actuel du système ; détecter et diagnostiquer le défaut naissant ; déterminer combien de temps à partir de ce moment une défaillance se produira compte tenu des conditions d'exploitation (Javed, 2014).

Le PHM peut être défini comme un ensemble de méthodes, d'outils et d'algorithmes qui fournissent aux opérateurs et aux utilisateurs des informations utiles, entre autres, pour maintenir en fonctionnement leur système, pour mieux planifier les interventions de maintenance, pour améliorer la conception future des produits en termes de maintenabilité et contrôlabilité (Sun et al., 2012), etc. Il utilise les connaissances disponibles sur le système et les données fournies par les capteurs ou recueillies à partir de l'exploitation pour estimer l'état de santé actuel du système,

détecter les anomalies, diagnostiquer les causes et prédire le délai de défaillance pour la prise de décision.

Le Prognostic and Health Management est un domaine d'ingénierie dont l'objectif est de fournir aux utilisateurs une analyse approfondie de l'état de santé d'une machine et de ses composants (Lee et al., 2014). Dans cette mesure, le PHM utilise des outils issus de la science des données, des statistiques et de la physique afin de détecter un éventuel défaut (détection d'anomalie) dans le système, le classer selon son type spécifique (diagnostic) et prévoir combien de temps la machine pourra fonctionner en présence de ce défaut (pronostic) (Kadry, 2012).

#### **1.4.1 Applications de PHM**

Initialement, la philosophie de gestion de la santé a été présentée pour les engins spatiaux dans les années 1970. Le PHM a commencé à réduire le taux d'accidents d'hélicoptères par l'Autorité de l'aviation civile du Royaume-Uni dans les années 1980 et a été développé en 1990 sur la base du système de surveillance HUMS (Health and Usage Monitoring System) qui mesure les conditions sanitaires et les performances de l'hélicoptère. La solution complète pour le pronostic et la maintenance des performances du système a été réalisée dans le projet Joint Strike Fighter F-35 (Smith et al., 1997). De plus, la capacité du PHM a déjà été répertoriée par le Département de la défense des États-Unis (DOD). Ceci montre l'implication significative du PHM dans les domaines militaires. D'autre part, la pratique industrielle indique que la technologie PHM peut réduire efficacement le coût de maintenance, améliorer la fiabilité et garantir l'achèvement des tâches du système (Pecht, 2009; Sun et al., 2012).

Avec des dizaines de milliers de chercheurs et de praticiens dans le monde entier, les applications du PHM sont aujourd'hui très vastes et englobent l'aérospatiale, l'énergie, la fabrication, la défense, le civil, l'automobile, le transport, la communication et les soins de santé. Les méthodologies de PHM ont le potentiel de fournir des moyens efficaces pour réduire les coûts associés à la maintenance de systèmes complexes, d'équipements ou d'installations grâce à une évaluation précise des dommages naissants, de la dégradation du système et à une prédiction fiable de la durée de vie restante au niveau des composants et du système.

Sun et al. (Sun et al., 2012) ont examiné certaines des pratiques et études de cas PHM dans leur publication, qui couvre un large éventail d'applications telles que la défense, l'aérospatiale, l'énergie éolienne, les infrastructures civiles, la fabrication et l'électronique. Yin et al. (Yin et al., 2016) ont publié une section spéciale pour collecter les applications PHM dans l'électronique industrielle.

Dans les industries lourdes et énergétiques, l'approche de PHM a été appliquée aux moteurs à turbine à gaz tels que Rolls-Royce industriel AVON 1535 (Li & Nilkitsaranont, 2008).

Komatsu et Caterpillar ont développé des algorithmes avancés d'analyse de données pour détecter les problèmes du véhicule à un stade précoce (Wang et al., 2007). Dans les applications d'énergie renouvelable, les systèmes de surveillance de l'état des transmissions d'éoliennes ont beaucoup progressé (Bechhoefer & Morton, 2012).

Dans l'industrie manufacturière, où l'accent est mis sur la réduction des temps d'arrêt, de nombreux travaux ont été consacrés à l'état de l'art de la technologie PHM pour les applications de fabrication, tels que (Jardine et al., 2006; Lee et al., 2014; Peng et al., 2010).

De nombreux organismes et centres (IMS, Fameto-ST, IVHM, NASA PCoE, etc.) de recherche travaillent actuellement dessus :

#### ***Centre IMS (Intelligent Maintenance Systems)***

L'IMS est un centre de recherche coopératif multi-campus NSF (National Science Foundation) Industry/University Cooperative Research Center (I/UCRC) composé de l'Université de Cincinnati (institution principale), de l'Université du Michigan - Ann Arbor, de l'Université des sciences et technologies du Missouri et de l'Université du Texas à Austin. Il a été créé en 2001 par l'Université de Cincinnati. Le Centre IMS mène des recherches multidisciplinaires axées sur l'intelligence artificielle industrielle ; Analyse prédictive de Big Data ; Systèmes cyber-physiques ; Pronostic and health management (PHM) et Industrie 4.0, entre autres domaines connexes (IMS, 2001)

#### ***FEMTO-ST***

L'institut FEMTO-ST (Franche-Comté Electronique Mécanique Thermique et Optique – Sciences et Technologies) est une institution de recherche commune créée en 2004 en France par la fusion de cinq laboratoires locaux, puis restructurée en sept départements. L'équipe PHM au sein du service de contrôle automatique développe des algorithmes avancés pour la classification, la prévision et la résolution de problèmes tels que le vieillissement des piles à combustible, les matériaux composites et les observations issues de réseaux de capteurs (Femto-st, 2004).

#### ***Integrated Vehicle Health Management (IVHM) Centre***

L'IVHM a été créé à l'Université de Cranfield (Bretagne) avec le soutien de Boeing en 2008 afin de devenir un centre de recherche de premier plan dans le monde pour l'étude PHM sur les aéronefs. Le centre a depuis lors offert le premier M.Sc (Master of science) en IVHM au monde

et accueille plusieurs doctorants qui effectuent des recherches sur l'application de l'IVHM à différents niveaux (IVHMC, 2008).

### ***Prognostics Center of Excellence (PCoE)***

Le PCoE, situé au centre de recherche de la NASA (National Aeronautics and Space Administration) Ames (California), fournit un cadre pour le développement de techniques visant en particulier à combler les lacunes technologiques en matière de pronostic dans les domaines d'application de l'aéronautique et de l'exploration spatiale. Le PCoE étudie actuellement les mécanismes de propagation des dommages sur les actionneurs critiques pour la sécurité des avions de classe transport, les mécanismes de dommages sur l'isolation du câblage des avions et les mécanismes de propagation des dommages sur les composants électriques et électroniques critiques des équipements avioniques (PCoE, 2006).

En outre, la PHM Society des États-Unis organise chaque année depuis 2008 le concours de données PHM pour le développement de techniques de prédiction. En tant qu'étude connexe, on relève le thème de prédiction de la durée de vie utile restante d'un turboréacteur dans cette compétition de données PHM. Il s'agit d'une étude qui prédit la durée de vie utile restante grâce à l'analyse des données de simulation (C-MAPSS Data : Commercial Modular Aero-Propulsion System Simulation) et calcule les scores pour l'évaluation des performances. On relève aussi les données de surveillance d'un moteur d'avion. Ce thème provenant de la base de données « PHM08 Challenge Data Set of Aircraft Engine ».

Ces deux bases de données font partie du Répertoire des données du Centre d'excellence en pronostics (PCoE) de la NASA, et qui sont détaillées dans le chapitre 4.

### **1.4.2 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 ;
- Prévision des interventions coûteuses de maintenance ;
- Réduction des coûts de maintenance ;
- 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 ;
- 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.

### **1.4.3 Architectures de PHM**

Dans la littérature, plusieurs architectures de PHM ont été proposées (Dragomir et al., 2009; Jardine et al., 2006; Zio & Di Maio, 2010). L'architecture OSA/CBM (Open System Architecture for Condition-Based Maintenance) proposée par M. Lebold et M. Thurston (Lebold & Thurston, 2001) est une compilation de sept tâches principales : acquisition des données – traitement – détection - diagnostique - pronostic - aide à la décision - interface homme-machine 'IHM'. OSA/CBM est une architecture détaillée de celle proposée par Muller (Muller, 2005). Cette est une Architecture SIMP (Système Intégré de Maintenance Prévisionnelle) qui doit remplir trois fonctions : Surveiller – Pronostiquer –décider. Dans la Figure (1.8) nous synthétisons les deux architectures.

#### ***Processus de surveillance***

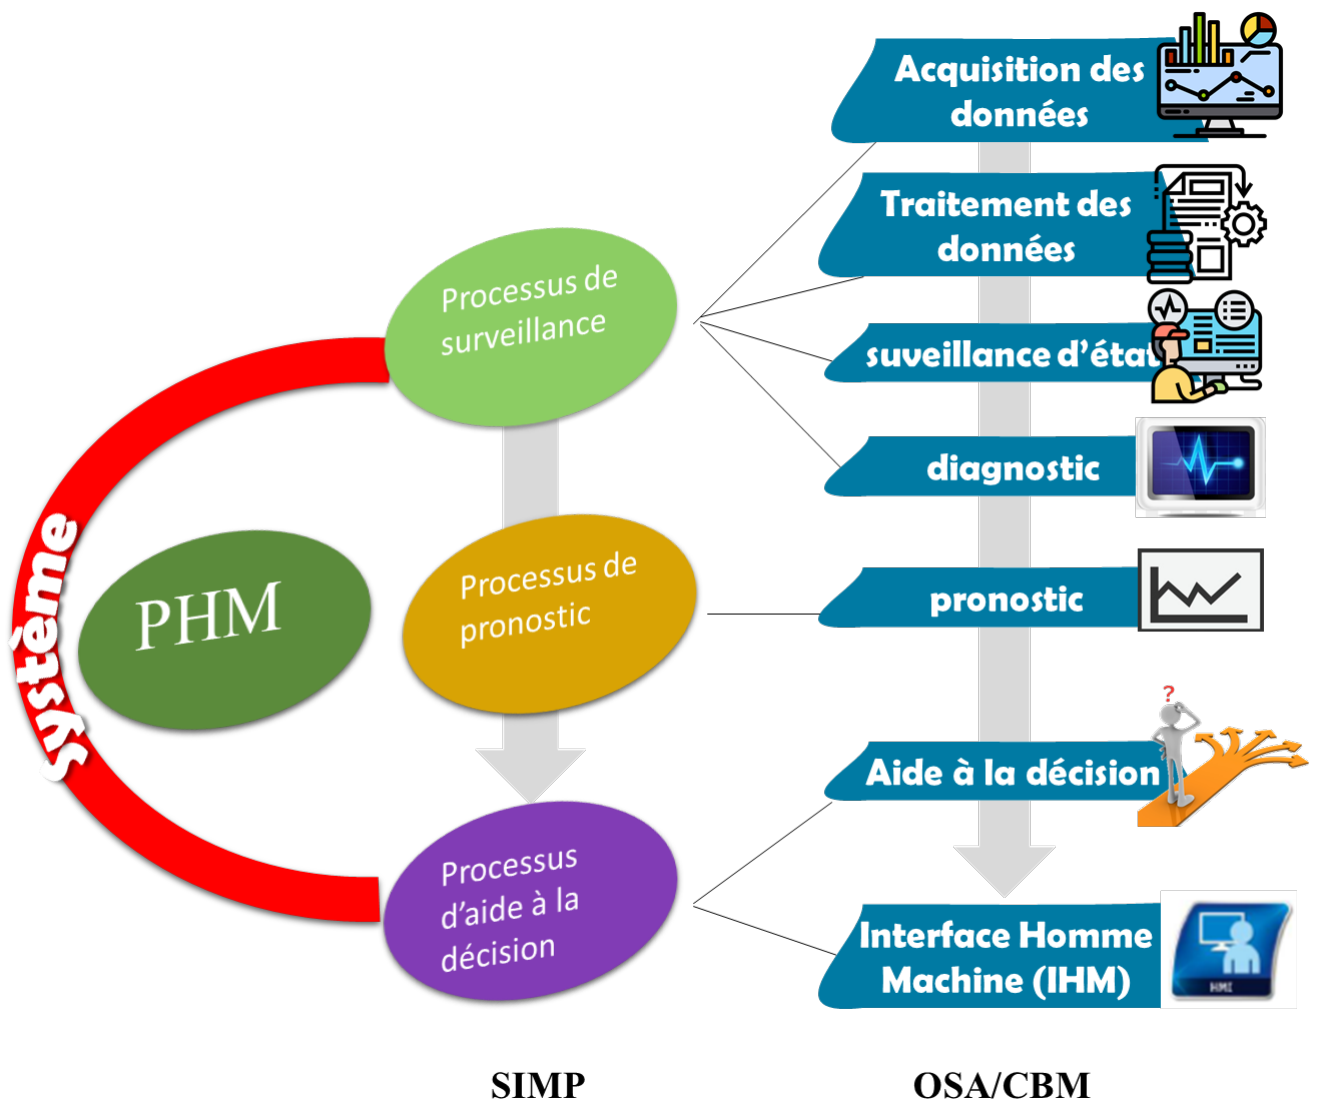
Le processus de surveillance est un dispositif passif qui détecte et classe les défaillances en observant l'évolution du système (processus de détection) puis les diagnostique en localisant les éléments défaillants et en identifiant les causes premières. C'est le rôle des quatre premières couches de l'architecture OSA/CBM :

- Module capteurs. Ce module fournit au système des données numériques issues de capteurs ou de transducteurs.
- Module traitement du signal : Ce module reçoit les données à partir des capteurs ou transducteurs ou d'autres processeurs de signaux et réalise des transformations de signaux et des extractions de caractéristiques ou de descripteurs.
- Module de surveillance. Le module de surveillance compare les données en ligne avec certaines valeurs attendues ou connues ; il doit également être capable de générer des alertes en fonction de seuils préalablement fixés.

- Module de diagnostic. Ce module détermine si l'état du système, sous-système ou composant surveillé est dégradé ou non et suggère les défaillances probables.

**Processus de pronostic**

Le processus de pronostic s'appuie sur les données issues du processus précédent afin de prédire l'état futur du système ou du composant surveillé, et de donner une estimation de la durée de fonctionnement avant défaillance (RUL).



**Figure 1.8** Architecture SIMP/OSA/CBM

### ***Processus d'aide à la décision***

Le processus d'aide à la décision à ce niveau en maintenance est défini comme un ensemble de méthodes et d'outils concourant au choix des meilleures actions à entreprendre selon les contraintes du moment. C'est le rôle des deux dernières couches de l'architecture OSA/CBM :

- Module d'aide à la décision : Sa fonction principale est de recommander des actions de maintenance ou d'autres alternatives pour continuer à faire fonctionner le système jusqu'à l'accomplissement de sa mission.
- Module de présentation : Ce module reçoit les informations de tous les modules précédents. Il peut être construit sous forme d'une IHM (Interface Homme-Machine).

## **1.5 CONCLUSION**

Afin de répondre aux impératifs de maintenance prédictive, le concept PHM (Prognostics and Health Management) s'avère être une voie prometteuse. A travers ce chapitre on constate que le PHM est un domaine de recherche et d'application qui vise à exploiter les informations passées, présentes et futures sur les conditions environnementales, opérationnelles et d'utilisation d'un équipement afin de détecter sa dégradation, diagnostiquer ses défauts, prévoir et gérer de manière prédictive ses défaillances. La principale divergence réside dans la nature des décisions à prendre : le PHM se veut plus général et adapté à tout type d'activité. Dans ce travail on s'intéresse plus particulièrement au processus de pronostic industriel.

## Chapitre 2: Pronostics guidés par les données

---

<u>2.1</u>	<u>Introduction</u> .....	33
<u>2.2</u>	<u>Pronostic</u> .....	33
<u>2.2.1</u>	<u>Définition</u> .....	34
<u>2.2.2</u>	<u>Durée de vie résiduelle</u> .....	35
<u>2.2.3</u>	<u>Approches de pronostic</u> .....	36
	<u>Approches basées sur l'expérience</u> .....	38
	<u>Approche guidée par les données</u> .....	38
	<u>Approche basée sur les modèles physiques</u> .....	41
	<u>Approches hybride</u> .....	42
<u>2.2.4</u>	<u>Avantages et inconvénients des approches de pronostic</u> .....	43
<u>2.2.5</u>	<u>Méthodologie de choix d'une approche</u> .....	44
<u>2.3</u>	<u>Pronostic guidée par les données - Etat de l'art</u> .....	46
<u>2.3.1</u>	<u>Régression par processus gaussienne</u> .....	46
<u>2.3.2</u>	<u>Réseaux neuronaux artificiels (ANN « Artificial Neural Network »)</u> .....	47
<u>2.3.3</u>	<u>Machine à vecteur de support</u> .....	50
<u>2.3.4</u>	<u>Relevance Vector Machine</u> .....	51
<u>2.4</u>	<u>Conclusion</u> .....	52



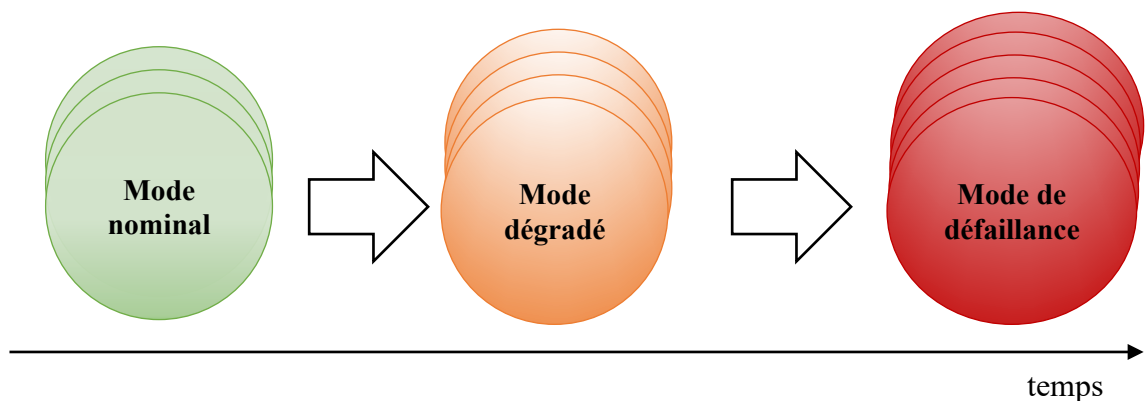
## 2.1 INTRODUCTION

Le Prognostic and Health Management (PHM) prend une part croissante dans le processus de pronostic industriel. Elle est considérée comme l'un des principaux leviers d'action dans la recherche de performance globale où trois approches de pronostic sont utilisées : l'approche basée sur l'expérience, l'approche guidée par les données et l'approche basée sur les modèles. Dans ce travail on s'intéresse au pronostic guidé par les données.

L'objet de ce chapitre est de présenter les différentes approches (2<sup>ème</sup> section) et plus particulièrement l'état de l'art des techniques utilisées dans l'approche guidée par les données (3<sup>ème</sup> section). La 2<sup>ème</sup> section débute par la définition du pronostic et de la durée de vie résiduelle et se termine par la présentation d'une méthodologie de choix d'une approche de pronostic. Enfin une conclusion clôture ce chapitre.

## 2.2 PRONOSTIC

Dans le cadre de la gestion de la santé industrielle, nous nous intéressons à la modélisation des changements dynamiques du système lorsqu'un ou plusieurs défauts<sup>1</sup> surviennent. Un modèle décrit les changements dans le système dans certaines conditions de santé. Tant qu'il n'y a pas de défaut, le système est en mode nominal. On suppose que la panne est permanente, c'est-à-dire que lorsqu'un défaut survient, le système entre dans un mode dégradé ou un mode de panne<sup>2</sup>, et ne reviendra pas au mode nominal s'il n'est pas réparé. Par conséquent, il peut se retrouver dans un mode de défaillance<sup>3</sup> où le système ne fonctionne plus. Cette évolution est illustrée à la Figure 2.1.



**Figure 2.1** Evolution unidirectionnelle d'un système sans maintenance ou action de réparation

<sup>1</sup> Un défaut représente un écart entre une caractéristique d'une entité et la caractéristique voulue, cet écart dépassant des limites d'acceptabilité.

<sup>2</sup> Panne est un écart du bien après la défaillance.

<sup>3</sup> Une défaillance perte de l'aptitude d'un bien à accomplir une fonction requise.

Lors de l'évaluation de l'état de santé du système, on pose les questions suivantes :

- Est-ce que le système est en état normal ? (Détection d'une anomalie)
- Si non, quelles sont les problèmes ? (Diagnostic)
- Quand est-ce que le système s'arrête de fonctionner ou dans combien de temps le système sera en mode de défaillance ? (Pronostic)

Le processus de pronostic prédit les trajectoires futures possibles et particulièrement la date d'entrée dans un mode défaillance (EOL ou End Of Life).

### 2.2.1 Définition

Donc le principe du pronostic est d'estimer la durée de vie résiduelle (RUL) des machines en prédisant l'évolution future à un stade précoce de la dégradation. Une estimation précise de la RUL permet de faire fonctionner l'équipement en toute sécurité tant qu'il est en état normal, ce qui profite en termes de temps supplémentaire pour planifier et préparer opportunément les interventions de maintenance pour les périodes les plus pratiques et les moins coûteuses.

D'une autre manière, le pronostic a pour but de garantir un intervalle maximal de réparation et de minimiser le nombre et le coût de réparation entre les pannes.

Selon la littérature, plusieurs définitions ont été proposées :

- Engel et al., (Engel et al., 2000): *Le pronostic est la capacité de fournir une détection précoce du précurseur et/ou de l'état de défaut naissant (très "petit" défaut) d'un composant, et de disposer de la technologie et des moyens de gérer et de prévoir la progression de cette condition de défaut jusqu'à la défaillance du composant.*

- Lebold & Thurston 2001 (Lebold & Thurston, 2001): "*Le pronostic est la capacité d'effectuer une prédiction fiable et suffisamment précise de la durée de vie utile restante d'un équipement en service. La fonction principale du pronostic est de projeter l'état de santé actuel de l'équipement dans le futur en tenant compte des estimations des profils d'utilisation futurs.*"

- Byington et al.(Byington et al., 2002) : "*Le pronostic est la capacité de prédire l'état futur sur la base de l'état de diagnostic actuel de la machine et des données disponibles sur son historique de fonctionnement et de défaillance.*"

Hess et al.,(Hess et al., 2006) : "*l'évaluation de l'état réel des matériaux, qui comprend la prédiction et la détermination de la durée de vie utile et des performances restantes des composants par la modélisation de la progression des défauts*".

Wu et al.,(Wu et al., 2007) : "*La prédiction des états de santé et des modes de défaillance futurs sur la base de l'évaluation de l'état de santé actuel, des tendances historiques et des charges d'utilisation prévues pour l'équipement et/ou le processus*".

Vachtsevanos (Vachtsevanos & Vachtsevanos, 2006) "*Le pronostic est la capacité de prévoir avec exactitude et précision la durée de vie utile restante d'un composant ou d'un sous-système défaillant*".

En 2004, la norme ISO 13381-1 définit aussi le pronostic comme :

« *Estimation de la durée de fonctionnement avant défaillance et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance* » (ISO13381-1, 2004).

En 2015, sa révision le décrit comme : « *l'analyse des symptômes des défauts dans l'intention de prédire l'état futur et la survie en fonction des paramètres de conception* » (ISO13381-1, 2015).

Selon la norme EN NF 13306 (2017) (NF EN 13306, 2017) la maintenance prédictive est défini comme :

« *Maintenance conditionnelle exécutée suite à une prévision obtenue grâce à une analyse répétée ou à des caractéristiques connues et à une évaluation des paramètres significatifs de la dégradation du bien* ».

### **2.2.2 Durée de vie résiduelle**

La durée de vie utile restante (Remaining Useful Life ; RUL) peut être définie comme :

« *La RUL est une durée avant que système ne tombe en dessous d'un seuil défini, c'est-à-dire l'intervalle de temps commençant à un instant donné et se terminant lorsque le taux de défaillance devient inacceptable, ou lorsque l'élément est considéré comme irréparable en raison d'un défaut ou pour d'autres facteurs pertinents* » (Sikorska et al., 2011).

À partir de cette définition, on peut se rendre compte que l'estimation de la RUL joue le rôle central dans la mise en œuvre des pronostics. La prédiction étant toujours incertaine, la gestion des incertitudes devient un enjeu important en pronostic. La RUL peut être définie comme le temps entre l'instant courant  $t_c$  et l'instant où la dégradation atteindra le seuil de défaillance  $t_{EOL}$  (Gouriveau et al., 2017).

C'est donc une estimation de la durée de vie restante d'un composant avant l'apparition d'une défaillance. La RUL est exprimée en unités correspondant à la mesure principale d'utilisation du système global. Par exemple, la mesure principale qui est en corrélation avec l'utilisation dans les avions commerciaux est le nombre de cycles (généralement mesurés par le nombre de décollages) ;

dans les moteurs d'avion, ce sont les heures de fonctionnement ; dans les automobiles, il s'agit de miles (ou kilomètres) parcourus ; dans les imprimantes ou copieurs, nombre de pages imprimées.

La fin de vie (EOL) est le cycle correspondant lorsque la dégradation atteint le seuil et que la maintenance doit être commandée pour le système. La dégradation étant une distribution, le cycle atteignant le seuil n'est pas une valeur déterministe. Par conséquent, l'EOL est également une distribution, en raison des mêmes sources d'incertitude, qui est représentée par la distribution sur le seuil comme montré à la Figure 2.2. La durée de vie Résiduelle (RUL) est également prédite comme une distribution en soustrayant le cycle actuel de la distribution EOL (Kim et al., 2017) :

$$RUL = t_{EOL} - t_c \mid t_{EOL} > t_c \quad (2.1)$$

Autrement dit, le pronostic consiste à prédire le comportement futur de la dégradation et la RUL du système sur la base des données mesurées jusqu'à l'heure actuelle.

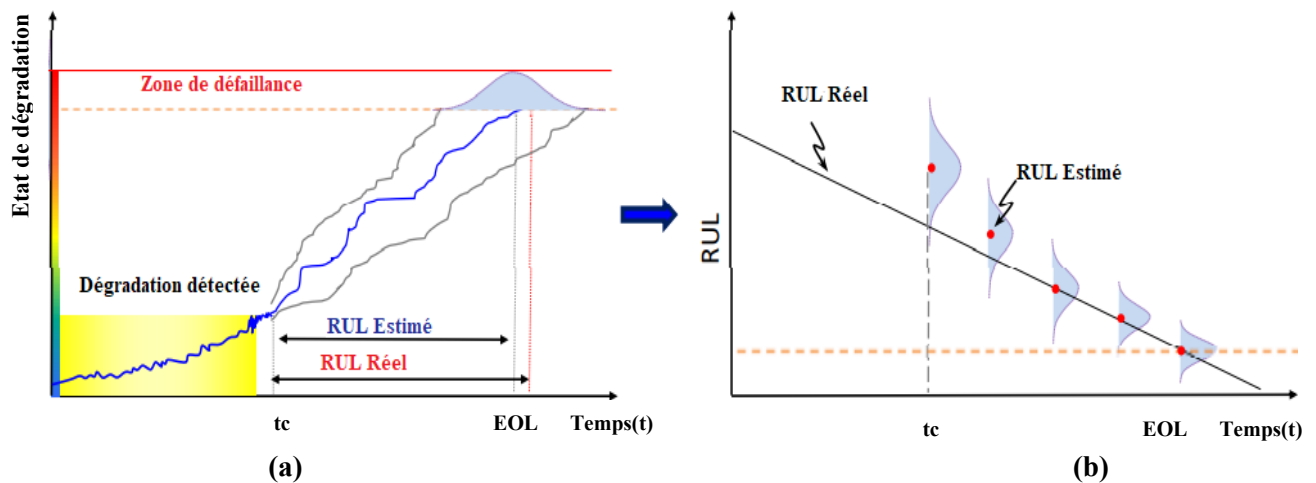


Figure 2.2 Estimation de la RUL (Gouriveau et al., 2017)

### 2.2.3 Approches de pronostic

Le processus de pronostic industriel tend à se développer rapidement ces dernières années, où différentes approches sont étudiées et en cours d'élaboration. De nombreuses classifications du pronostic des défaillances ont été proposées dans la littérature (Dragomir et al., 2009; Jardine et al., 2006; Peng et al., 2010; Sankararaman, 2015; Si et al., 2011), mais il n'existe pas de règle de classification universellement reconnue sur les méthodes.

La première a été proposée par Byington en 2002 (Byington et al., 2002), reprise par de nombreux travaux, et qui se présente sous forme d'une pyramide présentant trois approches : l'approche basée sur des modèles, l'approche basée sur les données et l'approche basée sur l'expérience, comme le montre la Figure 2.3. Les approches situées au sommet de la pyramide ont un coût de développement plus élevé étant donné qu'elles offrent une plus grande précision des résultats et sont aussi plus spécifique à l'application.

En 2006, Jardine et al (Jardine et al., 2006) ont proposé une nouvelle taxonomie des méthodes de pronostic basée en fonction du résultat attendu, en distinguant deux grandes catégories : l'estimation de la RUL et la probabilité de survie à une date donnée. Il s'agit du pronostic basé sur des outils statistiques, du pronostic utilisant des outils de l'intelligence artificielle et du pronostic avec modèles physiques (Figure 2.3).

En 2009, une autre classification a été proposée en fonction des formations de pronostic par Heng et al 2009(Heng et al., 2009) qui ont ajouté une quatrième approche appelée approche intégrée combinant le pronostic guidé par les données et le pronostic basé sur l'expérience (Figure 2.3).

Et récemment, Lee et al. (Lee et al., 2014) ont proposé trois approches : l'approche basée sur un modèle physique, l'approche guidée par les données et l'approche hybride qui est une intégration d'un modèle physique et d'une approche guidée par les données (Figure 2.3).

La Figure (2.4) récapitule l'éventail des approches de pronostic possibles en fonction des coûts de mise en œuvre relatif, de la précision des résultats et de la complexité. La Figure commence à la base : avec des modèles génériques, statistiques d'utilisation de la vie des systèmes et du pronostic basé sur l'expérience ; migre vers des techniques essentiellement basées sur les données utilisant des modèles évolutifs ou de tendance ; ensuite vers l'approche basée sur les modèles physique ; tandis que le sommet de la pyramide est occupé par l'approche hybride qui intègre l'approche physique et l'approche guidée par les données. Les technologies de pronostic utilisent généralement des caractéristiques mesurées ou inférées, en combinaison avec des modèles basés sur les données et/ou physique, pour prédire l'état du système à un moment futur (Engel et al., 2000; Orchard & Vachtsevanos, 2007). Le pronostic hybride au sommet de la pyramide, devrait guider le développement futur d'algorithmes de pronostic fiables et vérifiables pour des systèmes complexes tels que les avions (Gouriveau et al., 2017).

### ***Approches basées sur l'expérience***

Cette approche est la méthode traditionnelle d'estimation de la fiabilité. Elle est la moins complexe et elle s'appuie sur la modélisation stochastique de la dégradation ou sur des modèles fiabilistes. Elle ne nécessite que le retour d'expérience sur le composant étudié dans des conditions similaires (El Koujok, 2010). Il s'agit d'analyser ce retour d'expérience sur une population de composants identiques afin de déterminer une probabilité de défaillance sur un horizon temporel. Plusieurs modèles sont usuellement utilisés, tels que par exemple la loi exponentielle, log normale, gaussienne ou la loi de Weibull. La plus couramment utilisée d'entre elles est la distribution de Weibull en raison de sa capacité à décrire de nombreux types de comportements. Les distributions de pannes sont dérivées de données statistiques observées spécifiquement pour l'équipement. De telles données pourraient être facilement extraites des systèmes informatisés, de gestion de la maintenance, existants d'une entreprise (Sikorska et al., 2011).

Cette approche de prévision de la RUL modélise directement la relation entre les données de mesure et la RUL à partir de cas de défaillances historiques. Ces modèles peuvent prédire ou déduire directement la RUL sans qu'il soit nécessaire d'évaluer les critères de défaillance car aucune prédiction des états du système ne sera faite.

Malgré la perte évidente d'informations (par rapport aux approches basées sur les données), une distribution de pronostic basée sur la fiabilité statistique peut toujours être utilisée pour conduire des pratiques de maintenance basées sur des intervalles qui peuvent ensuite être potentiellement révisées par les informations obtenues à partir de la maintenance. L'avantage d'une base de données de maintenance régulièrement mise à jour est essentiel pour cette approche.

### ***Approche guidée par les données***

L'approche guidée par les données (ou '*data-driven approach*' en anglais) ne demande pas de modèles de système. Et elle est souvent considérée comme une "boîte noire" du fait de pouvoir apprendre le comportement du système directement à partir des données collectées dans les couches d'observation (Javed et al., 2016). Elle est basée sur l'utilisation directe des données de surveillance (Puissance, signaux vibratoires et acoustiques, température, pression, débit d'huile, courants, tensions, données calorimétriques, réponse en fréquence...etc) ou indirecte par l'intermédiaire d'indicateurs, sans recours à un modèle physique du comportement du système. L'indicateur est un événement, un fait observable, mesurable et déterminé par un calcul qui identifie de façon qualitative ou quantitative l'état de détérioration d'un composant, (Muller, 2005), qui permet de suivre, approcher et prévoir le comportement de dégradation du système (Luo et al., 2008). Abichou et al.(Abichou, 2013) ont défini un indicateur comme :

“Une grandeur reflétant une caractéristique de la santé, qu’elle soit de performance ou de dégradation. Il permet de quantifier la déviation par rapport au mode de fonctionnement nominal”.

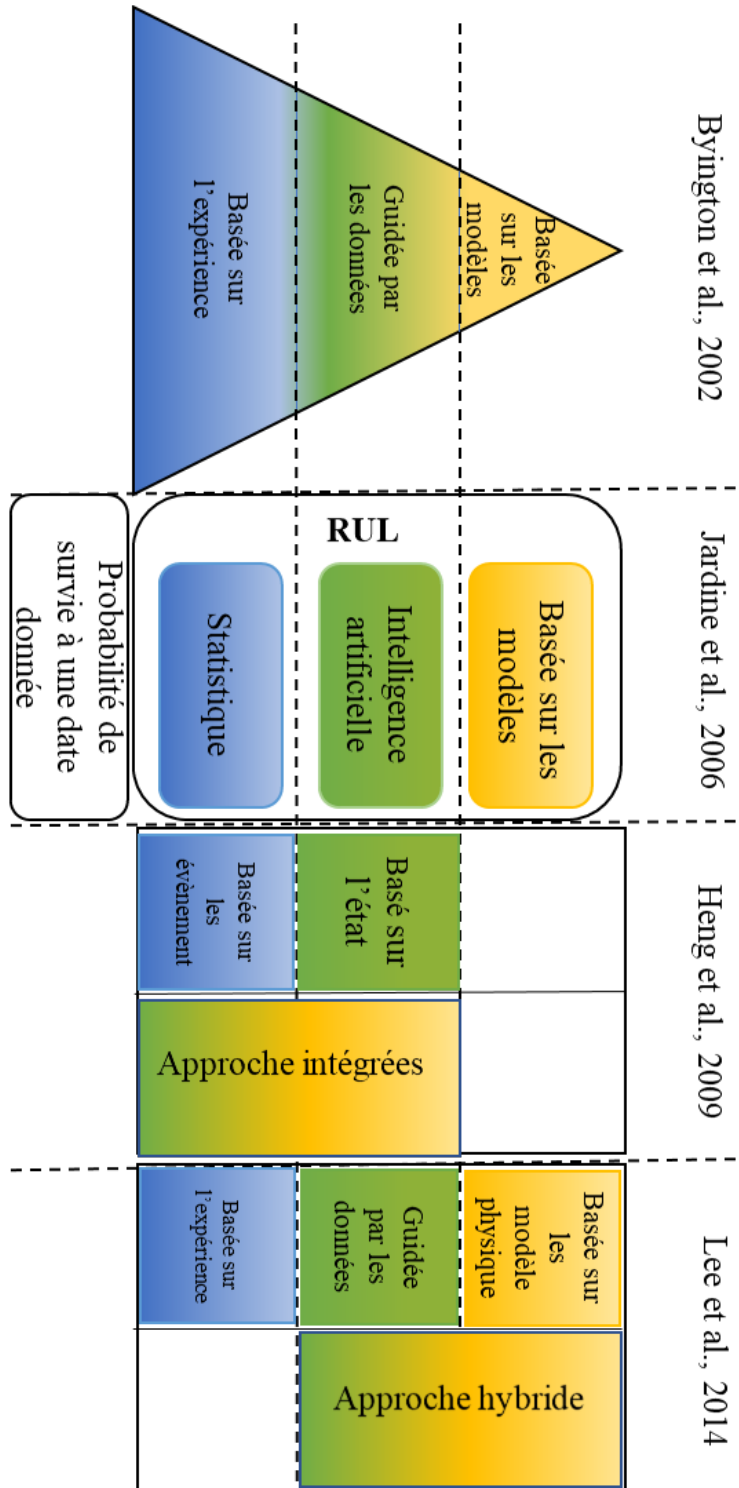
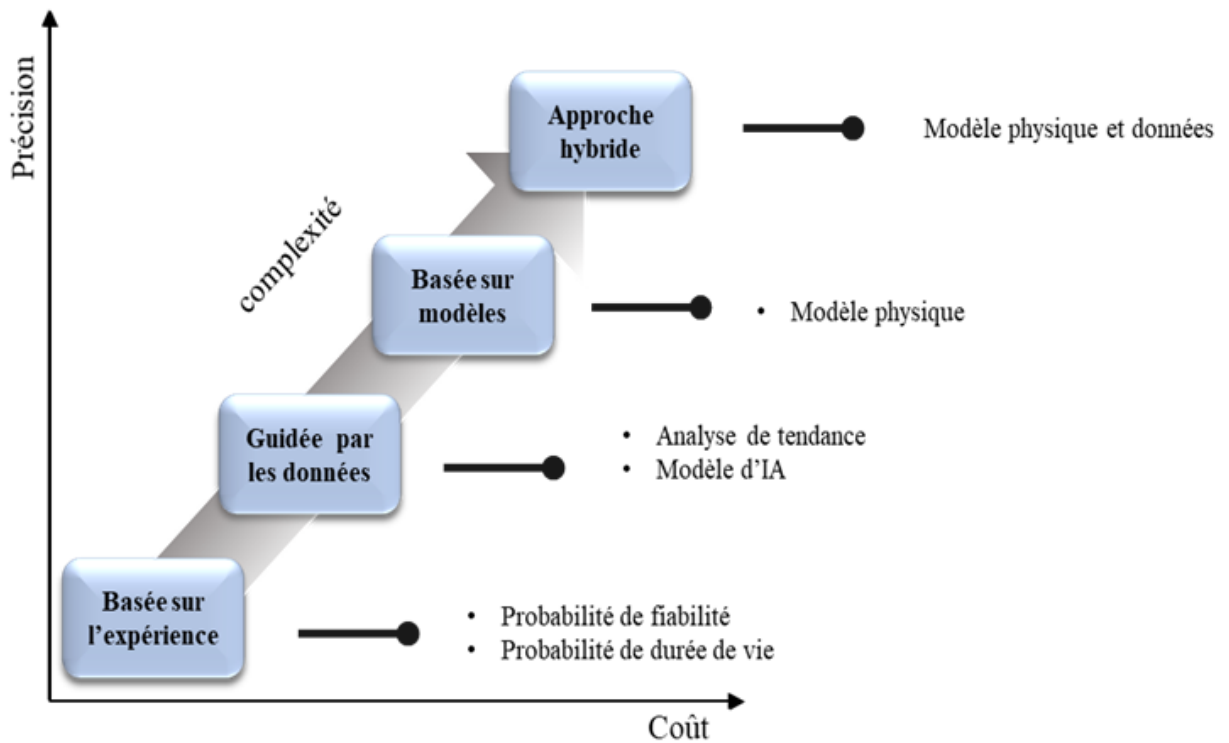


Figure 2.3 Synthèse des classifications des approches de pronostic



*Figure 2.4 Taxonomie des approches de pronostic*

Les données d'entrée/sortie mesurées sont la source principale pour obtenir une meilleure caractéristique reflétant le comportement du système et sa dégradation. Ces grandeurs sont ensuite utilisées pour apprendre des modèles de prédiction des états actuel et futur du système, et ainsi donner une estimation de la RUL.

Ce type de méthodes utilise des techniques d'apprentissage ou d'analyse de tendance afin de calibrer un modèle pour qu'il corresponde le mieux possible au composant étudié. L'avantage est que ces méthodes d'apprentissage peuvent identifier certaines corrélations entre les données.

Des stratégies axées sur les données pour les pronostics ont été appliquées dans diverses applications d'ingénierie (Al-Dahidi et al., 2017; Javed, 2014; Saxena et al., 2012; Silva et al., 2014). Il est généralement simple à mettre en œuvre, et il ne relie pas les phénomènes internes à l'observation externe ou aux états prédits. Cette approche est donc flexible à différents problèmes mais impose un coût élevé de collecte de données (Si et al., 2011 ; Tsui et al., 2015). Le pronostic guidé par les données est basé sur l'exploitation de symptômes ou bien d'indicateurs de la



dégradation dont l'évolution future est déterminée grâce à une méthode statistique ou d'intelligence artificielle.

Les méthodes de cette approche créent des relations non linéaires entre les entrées et les sorties sans modèle physique, mais ne sont pas nécessairement convergentes. L'un des avantages des méthodes basées sur les données est qu'elles peuvent être appliquées à n'importe quel niveau : système, sous-système ou composant (Sun et al., 2010). Les algorithmes de pronostic qui utilisent une approche basée sur les données apprennent des modèles directement à partir des données, plutôt que d'utiliser des modèles construits sur la base de l'expertise humaine (Schwabacher, 2005).

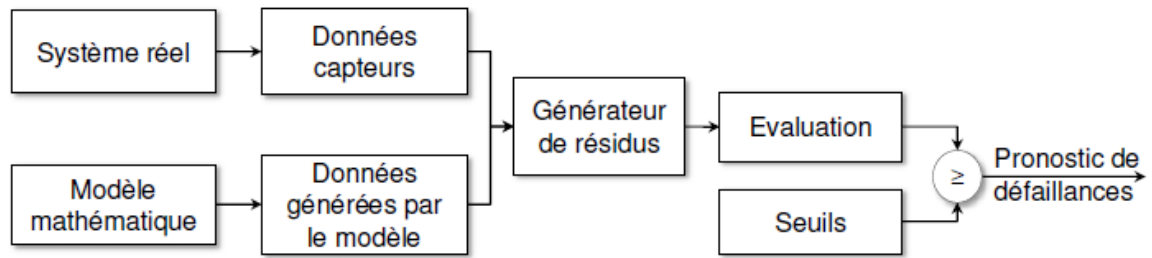
### *Approche basée sur les modèles physiques*

L'approche basée sur les modèles physiques est une approche qui conduit à un résultat précis, à condition de disposer d'un modèle physique fiable et réaliste de la dégradation.

L'hypothèse fondamentale est qu'il existe un modèle physique qui décrit l'évolution des dommages ou de la dégradation. Pour cette raison, le modèle physique est souvent appelé modèle de dégradation, et c'est pourquoi l'approche est souvent appelée aussi pronostic basé sur un modèle. S'il existe un modèle physique précis qui décrit la dégradation des dommages en fonction du temps, cela renforce avec robustesse le pronostic car le comportement futur des dommages peut être déterminé en faisant progresser le modèle de dégradation dans le temps futur.

Ce type d'approche utilise des équations mathématiques pour décrire les phénomènes de dégradation et prédire la physique régissant les défaillances. Les méthodes basées sur un modèle physique requièrent la construction d'un modèle dynamique représentant le comportement du système, et intégrant le phénomène de dégradation (tels que les modèles de fatigue, d'usure, de corrosion, ...) dont l'évolution est modélisée par une loi déterministe ou un processus stochastique (Fan et al., 2011; Jouin et al., 2016; Wang et al., 2013; Xing et al., 2013). L'utilisation de cette approche nécessite des connaissances spécifiques liées aux mécanismes de défaillance (fracture due à des fissures, usure, fatigue, corrosion, ...) ainsi qu'au mode de fonctionnement du système analysé.

Les approches basées sur les modèles physiques utilisent les résidus comme résiduels en tant que caractéristiques, où les résidus sont les résultats de comparaison entre les mesures détectées des données de capteurs issues de système et le modèle mathématique réel (Figure 2.5). Les résidus, qui correspondent aux différences entre les deux types de données, sont ensuite évalués. En l'absence de défaut, les résidus sont statistiquement nuls. En présence d'un défaut, les résidus dépassent des seuils de détection de défauts (Peng et al., 2010).



**Figure 2.5** Approche de pronostic basée sur le modèle physique

Cette approche est donc dédiée aux applications spécifiques qui ont été développées et repose sur l'hypothèse que le comportement du système peut être décrit analytiquement tout en restant précis. Cependant, les connaissances nécessaires ne sont pas toujours disponibles ou matures. Ainsi il est souvent déployé dans une application où la précision domine. En pratique, cependant, le modèle de dégradation n'est pas complet et les conditions d'utilisation dans le futur sont incertaines. Par conséquent, les problèmes clés des pronostics basés sur la physique sont de savoir comment améliorer la précision du modèle de dégradation et comment incorporer l'incertitude à l'avenir (Kim et al., 2017). Donc leur inconvénient majeur réside dans le fait que, pour un système réel, il est difficile (parfois même impossible) d'obtenir le modèle dynamique sous forme analytique pour intégrer le phénomène de dégradation. Ces modèles sont généralement coûteux en temps mais aussi en niveau de compétences des concepteurs / développeurs. Par conséquent, le modèle construit pour une application ne peut pas être transféré à une autre application.

### ***Approches hybride***

L'approche hybride utilise à la fois les méthodes des approches basées sur le modèle physique et guidées par les données, combine leurs avantages et tire parti de leurs forces pour améliorer les performances de prédiction (Liao & Köttig, 2014). En effet, les méthodes guidées par les données sont utilisées pour mettre à jour les paramètres du modèle basé sur le modèle physique, ce qui maximise leur capacité de prédiction. Cependant, les inconvénients des deux approches sont également accumulés.

Il est nécessaire de disposer des deux types de connaissances, une description précise du modèle physique et une base de données suffisante. Les coûts de mise en œuvre sont donc de plus en plus élevés.

Deux classes de pronostic hybride sont généralement distinguées (Figure 2.6). Lorsque qu'un modèle physique (même empirique) peut être établi, une approche orientée données est utilisée afin d'estimer et de prédire les paramètres non observables du modèle. On parle alors

d'approche hybride "série" (Dong et al., 2014; Fan et al., 2015; Hu et al., 2015). Une approche dite "parallèle" (ou "fusion") consiste à combiner la sortie d'un modèle physique à celle d'un outil orienté données pour reconstruire la sortie d'ensemble (Pecht, 2010). Dans de tels cas, l'outil orienté données est généralement utilisé pour estimer et prédire les phénomènes non expliqués et donc non modélisés.

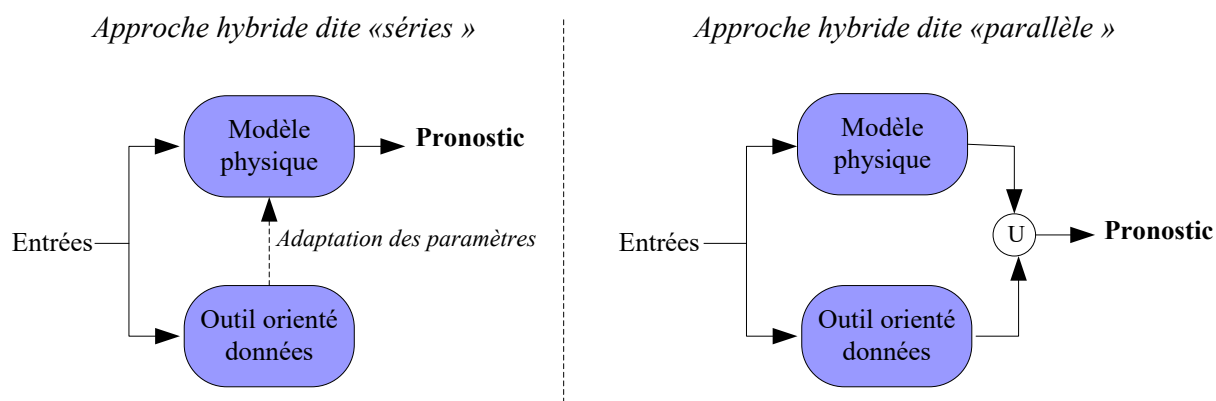


Figure 2.6 Approche de pronostic hybride (série et parallèle)(Gouriveau et al., 2017)

### 2.2.4 Avantages et inconvénients des approches de pronostic

On synthétise dans le tableau 2.1 les avantages et les inconvénients des différentes approches.

Tableau 2.1 Les approches de pronostic

Approches de pronostic	Avantages	Inconvénients
<b>Approche basée sur l'expérience</b>	<ul style="list-style-type: none"> <li>- Applicabilité très large. Relativement simple à mettre en œuvre et pas contenu.</li> </ul>	<ul style="list-style-type: none"> <li>- Nécessite un historique d'expression passée.</li> <li>- Moins précise.</li> <li>- Les données sont généralement incomplètes.</li> <li>- Le temps nécessaire à leur collection peut être très important.</li> </ul>

<p><b>Approche guidée par les données</b></p>	<ul style="list-style-type: none"> <li>- Adaptée à tout type d'application instrumenté.</li> <li>- Connaissance des mécanismes de dégradation directement incluse dans les données.</li> <li>- Ne nécessite pas la connaissance de modèles analytique des dégradations.</li> </ul>	<ul style="list-style-type: none"> <li>- Nécessité des scénarios de dégradation pour différentes conditions opérationnelles.</li> <li>- Acquisition et couverture données d'apprentissage</li> </ul>
<p><b>Approche basée sur le modèle physique</b></p>	<ul style="list-style-type: none"> <li>- Précise.</li> <li>- Meilleure performance de pronostic obtenues.</li> <li>- Flexibilité de l'approche.</li> </ul> <p>Interprétable</p>	<ul style="list-style-type: none"> <li>- Difficile</li> <li>- Coûteux d'obtenir le modèle mathématique.</li> <li>- Les phénomènes de dégradation ne sont pas exhaustive</li> <li>- Chaque composant a un propre modèle ou les lois de fiabilité</li> <li>- Nécessite une connaissance liée au mécanisme de dégradation</li> </ul>
<p><b>Approche hybride</b></p>	<ul style="list-style-type: none"> <li>- Peut être utilisée avec un manque de données</li> <li>- Prédiction précises</li> </ul>	<ul style="list-style-type: none"> <li>- Grande complexité de mise en oeuvre.</li> <li>- Nécessite à la fois les données événementielles et d'observation.</li> </ul>

### 2.2.5 Méthodologie de choix d'une approche

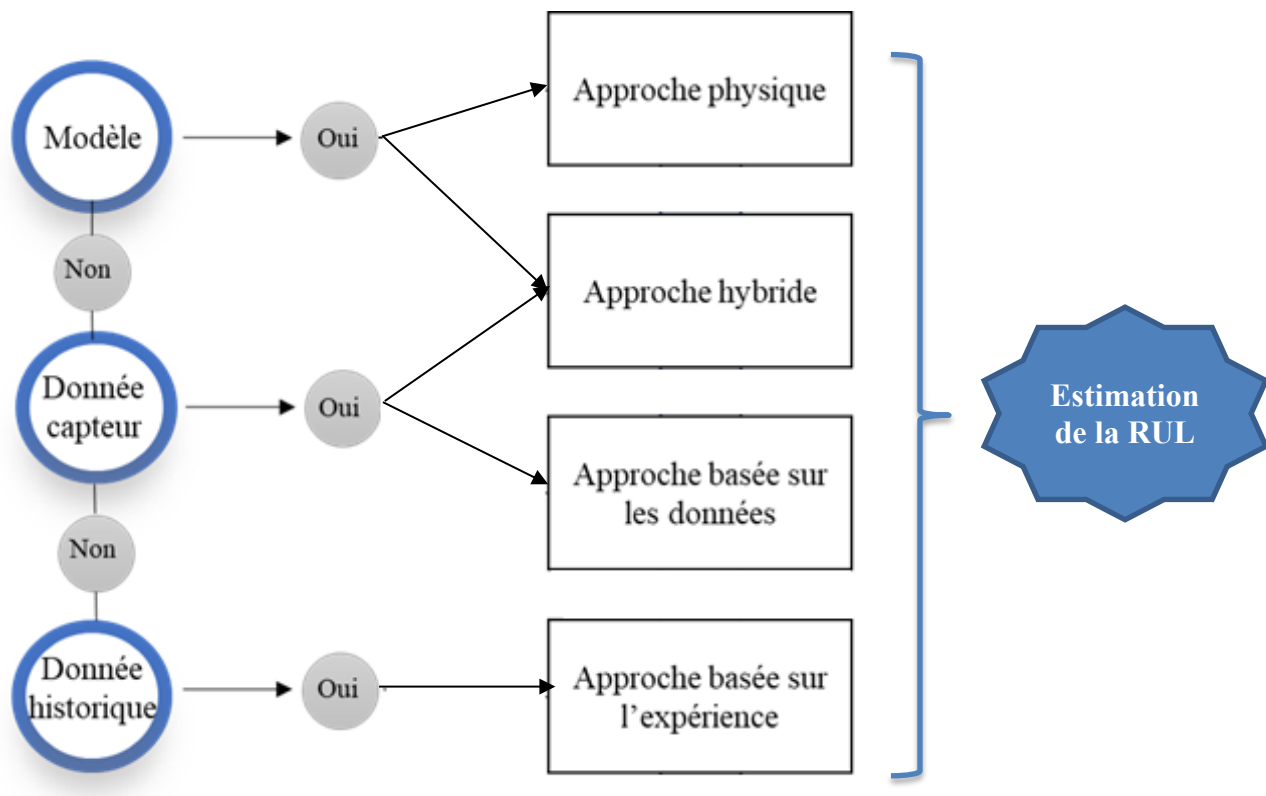
Le choix d'une approche dépend de la disponibilité des données appropriées. S'il existe un modèle physique précis qui décrit la dégradation des dommages en fonction du temps, alors cela renforce fondamentalement l'approche pronostic basée sur le modèle physique car le comportement futur des dommages peut être déterminé en faisant progresser le modèle de dégradation dans le temps futur.

Pour les situations dans lesquelles des modèles de pronostic précis ne sont pas ou ne peuvent pas être utilisés (peut-être parce qu'un investissement élevé dans de tels modèles n'est pas justifié par l'analyse de rentabilisation, de faibles taux de criticité des défaillances), l'approche basée sur les données peut être alternative. L'approche basée sur les données utilise directement les données de surveillance issues de capteurs qui représentent l'état actuel du système. L'approche hybride nécessite à la fois les données de capteurs et modèles physiques.

La seule alternative possible lorsque les trois approches ci-dessus ne peut être mises en place est l'approche basée sur l'expérience. Elle ne nécessite que l'historique des défaillances afin de déterminer la probabilité de défaillance à un moment donné dans le futur.

Les quatre approches ont pour but de donner une estimation de la RUL. On propose la méthodologie de choix de l'approche de pronostic illustré en Figure 2.7.

Dans la suite de ce chapitre, on s'intéresse au pronostic guidé par les données. Il s'agit de présenter un état de l'art des différentes méthodes utilisées dans cette approche.



**Figure 2.7** Méthodologie de choix d'une approche de pronostic

## 2.3 PRONOSTIC GUIDEE PAR LES DONNEES - ETAT DE L'ART

Plusieurs méthodes de pronostic guidée par les données ont été utilisées dans la littérature. On distingue deux catégories : les méthodes statistiques et les méthodes d'apprentissage automatique ou d'intelligence artificielle. On peut citer les méthodes utilisées dans les travaux suivants, d'une part : la régression par processus gaussien (Seeger, 2004), le processus gamma (Pandey & Van Noortwijk, 2004; Wang et al., 2013), le processus de Wiener (Le Son et al., 2013; Si et al., 2013; Zhang et al., 2018), le modèle de Markov et Markov caché (Liu et al., 2012; Medjaher et al., 2012). D'autres part, l'apprentissage automatique (Javed et al., 2017), la machine à vecteurs de support (SVM :Support Vector Machine), machine à vecteur de pertinence (RVM : Relevance Vector Machine) (Benkedjouh et al., 2015; Tipping, 2001; Yan et al., 2013), les réseaux de neurones Artificiel (ANN) (Ahmadzadeh & Lundberg, 2013; Li et al., 2013). Quelques méthodes sont présentées ci-dessous.


### 2.3.1 Régression par processus gaussienne

La régression par processus gaussienne (GPR : Gaussian Process Regression) est un ensemble de variables aléatoires dont un nombre fini a une distribution gaussienne conjointe. Elle intègre des variables multiples en ajustant une distribution normale, puis applique la règle de Bayes pour prédire le futur sur la base du passé. Cependant, elle a des exigences relativement coûteuses en termes de mémoire et de CPU, et peut donc ne pas convenir à un fonctionnement en ligne. Une solution à ce problème est de distribuer la mise en œuvre comme dans (Saha et al., 2010). Plusieurs chercheurs ont utilisé cette technique dans le pronostic. Goebel (Goebel et al., 2008) et Saha (Saha et al., 2010) ont appliqué la méthode de régression du processus gaussien pour la prédiction de les RULs des batteries. Aye et Heyns (Aye & Heyns, 2017) ont proposé la régression pour estimer les RULs des roulements à vitesse lente.

Dans (Medjaher et al., 2012) il est proposée une approche basée sur le modèle de Markov caché pour prédire la dégradation des roulements. Là, il est supposé que les densités de probabilité d'observation soient un mélange de densités gaussiennes et qu'il existe des signaux provenant des capteurs qui peuvent capter la dégradation des relèvements. Ainsi, les données des capteurs peuvent être utilisées pour estimer les paramètres des distributions et par conséquent la RUL. Nagi et al (Nagi et al., 2019) ont utilisé la régression par processus gaussien (GPR) pour prédire la RUL de roulements aussi.

### 2.3.2 Réseaux neuronaux artificiels (ANN « Artificial Neural Network »)

L'origine des réseaux de neurones artificiels provient de l'imitation du processus de travail du cerveau humain qui relie de nombreux nœuds dans une structure de couche complexe. Ils sont bien adaptés à un certain nombre d'applications telles que la reconnaissance des formes et le traitement du signal. La Figure 2.8 présente un exemple de réseau de neurone avec 2 couches cachées (Sikorska et al., 2011).



*Figure 2.8 Exemple d'un réseau de neurones artificiels*

Les réseaux de neurones artificiels sont aussi parmi les techniques de l'IA les plus utilisées dans le domaine de la prédiction. Ils peuvent être considérées comme un approximateur de fonction, à boîte noire, non linéaire à entrées et sorties multiples. L'ANN peut jouer différents rôles dans les applications de pronostic, tels que l'estimation d'état, la prédiction d'état ou directement la modélisation de la RUL, selon la manière dont les entrées et les sorties sont construites.

Plusieurs chercheurs ont utilisé les ANN pour la prédiction (Elforjani, 2016; Gebraeel et al., 2004; Gebraeel & Pan, 2008; Huang et al., 2007; Lu et al., 2014; Sun et al., 2010; Yang et al., 2016). Schwabacher (Schwabacher, 2005) a présenté une brève revue du pronostic guidé par les données utilisant divers réseaux neurones artificiels. Saon et al (Saon & Hiyama, 2010) ont utilisé un réseau neuronal à anticipation et l'algorithme d'apprentissage de Levenberg-Marquardt pour prédire les RULs des roulements. Peng et al. (Peng et al., 2012) ont amélioré un ANN en remplaçant à l'aide d'un grand réservoir clairsemé pour remplacer la couche cachée de RNN et ont développé une nouvelle approche de prédiction des RULs de turboréacteurs à partir de l'ensemble des données de la NASA (C-MAPSS). Liu et al. (Liu et al., 2013) ont proposé un réseau de

neurones récurrents (RNN : Recurrent Neural Network) pour la prédiction des RULs des batteries lithium-ion en améliorant la propriété de mémoire des ANN. Rodriguez, et al (Rodríguez et al., 2013) ont présenté un ANN à six couches d'entrée, trois couches cachées et une couche de sortie, pour prédire et simuler le comportement de l'évaluation du cycle de vie des aubes de turbines à vapeur.

D'autres types d'ANN ont été utilisés (Javed et al., 2014, 2015; Li et al., 2013; Pan et al., 2014) dans le domaine de la prédiction de RULs des machines. Wang & Vachtsevanos (Wang & Vachtsevanos, 2001) ont utilisé un réseau de neurones à ondelettes (WNN, Wavelet Neural Network) qui sont une classe de réseaux qui combinent les réseaux de neurones sigmoïdes classiques (NNs : classic sigmoïde neurones) et l'analyse d'ondelettes (WA, Wavelet analysis). Ils l'ont appliqué pour évaluer des fissures à partir d'indicateurs puis ont utilisé les réseaux de neurones à ondelettes dynamiques (DWNN : Dynamic Wavelet neural networks) pour prédire le processus de propagation des fissures et estimer leurs durées de vie utile.

Actuellement, plusieurs méthodes d'apprentissage approfondies sont développées pour la prédiction de la RUL, telles que :

Les réseaux de neurones convolutifs (CNN : Convolutional Neural Network) qui sont très similaires aux réseaux de neurones classiques. Ils sont constitués de neurones qui ont des poids et des biais pouvant être appris. Chaque neurone reçoit des entrées, effectue un produit scalaire et le suit éventuellement avec une non-linéarité. Babu et al., (Sateesh Babu et al., 2016) ont appliqué un réseau de neurones convolutifs, CNN, pour estimer les RULs de turboréacteurs. Li et al., (Li et al., 2018) ont proposé une nouvelle approche de pronostic guidée par les données pour estimer les RULs des turboréacteurs, à partir de l'ensemble des données de C-MAPSS), utilisant les réseaux de neurones à convolution profonde (DCNN : Deep Convolutional Neural Network). Li et al (Li et al., 2020) ont proposé un réseau neuronal à convolution profonde multi-échelle, MS-DCNN (Multi-Scale Deep Convolutional Neural Network), en utilisant l'ensemble de données C-MAPSS pour des turboréacteurs. Jayasinghe et al (Jayasinghe et al., 2019) ont également utilisé ces données pour construire le modèle basé sur le réseau à mémoire conventionnelle temporelle (TCMN, Temporal Conventional Memory Network).

Les réseaux de neurones récurrents (RNN) « Recurrent Neural Network » (Deutsch & He, 2017; Sateesh Babu et al., 2016; Zhu et al., 2018) sont également largement utilisés dans la prédiction des RULs en raison de leur capacité à traiter des données chronologiques explicites. Les RNN sont une classe de réseaux neuronaux artificiels où les connexions entre les nœuds forment un graphe dirigé le long d'une séquence temporelle. Zemouri et al. (Zemouri & Gouriveau, 2010;



Zemouri et al., 2003) ont proposé un réseau récurrent à fonctions de base radiales (RRBFN : Recurrent Radial Basis Function Network) et l'ont utilisé pour prédire la RUL des Fournaise au gaz. Heimes (Heimes, 2008) a proposé une méthode pour prédire la RUL des turboréacteurs (données de PHM'08 challenge dataset) en utilisant le RNN traditionnel formé avec une rétro-propagation et une formation étendue au filtre de Kalman. Ses résultats ont été en mesure de prédire avec précision la RUL et a obtenu la deuxième place du concours PHM 2008. Malhi et al. (Malhi et al., 2011) ont proposé une approche basée sur l'apprentissage compétitif pour réviser la technique de d'apprentissage des RNN visant à améliorer la précision des prévisions à long terme des roulements. Zhang et al. (Zhang et al., 2018) ont affiné les réseaux de neurone récurrents établis et ont obtenu les résultats de prédiction souhaités à partir de l'ensemble de données C-MAPSS. Cet ensemble de données a également été utilisé dans (da Costa et al., 2020), Al-Dulaimi et al. (Al-Dulaimi et al., 2019) et Wang et al. (Wang et al., 2019) qui ont proposé un cadre de réseau neuronal profond hybride pour l'estimation de la durée de vie utile restante de turboréacteurs.

Le LSTM « Long Short Term Memory » est un RNN avancé, un réseau séquentiel, qui permet à l'information de persister. Il est une variante du RNN conçue pour apprendre les dépendances à long terme. Le LSTM introduit l'idée d'une cellule de mémoire, qui contient des portes qui tentent de réguler l'information à travers la cellule. Le résultat est un réseau qui obtient des poids contextuels qui peuvent traiter les dépendances à long terme de manière flexible.

Beaucoup de chercheurs utilisent le LSTM pour estimer la RUL. Wu et al. (Wu et al., 2018) l'ont utilisé pour estimer RULs des turboréacteurs. De plus, ils ont comparé leurs performances avec celles du RNN traditionnel et ils ont constaté que les performances du LSTM étaient bien meilleures. Yuan et al. (Yuan et al., 2016) ont également utilisé le LSTM sur des moteurs de turboréacteur, mais à la fois pour le diagnostic et le pronostic. Ils visaient à prédire la RUL linéaire par morceaux et la probabilité d'apparition de défauts. L'ensemble de données ne contenant pas de défaut, ils ont utilisé une approche de machine à vecteur de support (SVM) pour détecter les anomalies et les utiliser pour les défauts. Ellefsen et al. (Ellefsen et al., 2019) ont proposé une architecture semi-supervisée profonde pour prédire les RULs sur des turboréacteurs. En 2017, Zheng et al. (Zheng et al., 2017) ont combiné des séquences de couches LSTM et de couches CNN normales pour estimer les RULs à la fois sur des turbomoteurs et des machines-outils. Hinch et Tkiouat (Hinch & Tkiouat, 2018) ont proposé une approche qui combine un LSTM et un réseau neuronal convolutif (CNN). La couche de convolution a été utilisée pour extraire des indicateurs directement sur les données de vibration des roulements. Les indicateurs ont été à une couche LSTM qui a prédit les RULs des roulements. Zhang et al. (Zhang et al., 2018) ont proposé une

méthode basée sur le LSTM pour prédire la durée d'utilisation des batteries lithium-ion. Afin de gérer les incertitudes dans les prédictions, ils ont utilisé la méthode de simulation de Monte Carlo. Elsheikh (Elsheikh et al., 2019) ont proposé des (LSTM) pour créer un modèle de dégradation LSTM pour prédire les RULs des turboréacteurs en utilisant l'ensemble de données C-MAPSS.

### **2.3.3 Machine à vecteur de support**

La technique des machines à vecteurs supports (SVM, Support Vector Machine) est une méthode d'apprentissage statistique (Nieto et al., 2015). les SVMs sont l'une des techniques d'intelligence Artificielle (IA) basée sur la théorie de l'apprentissage statistique, introduite par Vladimir Vapnik (Vapnik, 1999). Les SVMs sont à l'origine utilisées pour la classification binaire et la régression. Aujourd'hui, elles sont utilisées dans différents domaines de recherche et d'ingénierie tel que le diagnostic médical, le marketing, la biologie, la reconnaissance de caractères manuscrits et de visages humains et aussi dans le pronostic.

Différents types de SVM ont été appliqués à la prédiction des RULs des machines (Caesarendra et al., 2011), telles que la SVM des moindres carrés (LS- SVM, Least Squares-Support Vector Machine) (Dong & Luo, 2013; Lu et al., 2016; Niu & Yang, 2010), la SVM à une classe (Carino et al., 2015; Jin et al., 2019) et la SVM à plusieurs classes (Kimotho et al., 2013; Sloukia et al., 2013).

Widodo et Yang (Widodo & Yang, 2011) ont formé le modèle SVM en utilisant à la fois les données censurées et complètes, et prédit la probabilité de survie de roulements. Caesarendra, et al (Caesarendra et al., 2011), ont combiné le modèle de risque proportionnel de Cox et la SVM pour la prédiction de la défaillance par dégradation de roulements aussi. Soualhi (Soualhi et al., 2014) ont utilisé également la méthode SVM pour créer un modèle de dégradation des roulements. Ordóñez et al (Ordóñez et al., 2019) ont utilisé les résultats de la méthode ARIMA (Autoregressive Integrated Moving Average), méthode mobile intégrale auto-régressive, qui estime à l'avance les valeurs des variables prédictives pour créer un modèle de dégradation des moteurs d'avion avec la méthode SVM. Une nouvelle méthode d'estimation de la RUL en temps réel, des batteries Lithium-ion, avait proposée par Patil et al (Patil et al., 2015) qui ont intégré les attributs de classification et de régression de l'apprentissage automatique basé sur la technique SVM. Plus de littérature publiée sur l'application de la SVM dans l'estimation RUL des systèmes mécaniques peut être trouvée dans les réfs (Pan et al., 2009; Zhang et al., 2015).

Benkedjough et al.(Benkedjough et al., 2013) et Saidi (Saidi et al., 2015) ont utilisé la régression vectorielle de support, SVR, pour estimer les RULs des roulements dans une application

mécanique. La SVR est un algorithme de régression qui permet d'utiliser des valeurs continues, au lieu de la classification SVM. Rabiei et al (Rabiei et al., 2016) ont également appliqué la méthode SVR pour définir une corrélation entre les variables d'entrée, leur objectif était d'estimer les dommages et de prévoir l'apparition de fissures dans un alliage métallique sujet à la fissuration par fatigue. Fumeo et al. (Fumeo et al., 2015) ont développé un modèle SVR en ligne pour la prédiction des RULs de roulements en optimisant le compromis entre précision et efficacité de calcul. Benkedjough (Benkedjough et al., 2015) ont appliqué cette méthode pour estimer l'augmentation de l'usure dans une fraiseuse à grande vitesse et prédire sa RUL. Nieto et al (Nieto et al., 2015) ont mis au point un modèle hybride qui intègre la SVR et le PSO (Particle Swarm Optimizatio) pour effectuer l'estimation des RULs de moteurs d'avion. Ils ont utilisé PSO dans le processus de détermination des meilleurs hyperparamètres du modèle SVR. Khelif et al (Khelif et al., 2016) ont conçu un indice de santé pour construire les modèle de dégradation des turboréacteurs utilisant la SVR. Quelques autres approches de prédiction basées sur la SVR ont ainsi été développées dans (Liu et al., 2015; Loutas et al., 2013; Patil et al., 2015). Xue et al. (Xue et al., 2020) ont mis en œuvre un modèle intégré comprenant la méthode AUKF (Adaptive Unscented Kalman Filter), une SVR et un algorithme génétique pour estimer avec succès la RUL d'une batterie lithium-ion. Dans leur étude, l'algorithme génétique a été utilisé pour optimiser les paramètres de la SVR, et la prédiction à plusieurs étapes a été appliquée.

### **2.3.4 Relevance Vector Machine**

Malgré l'application répandue des SVMs, ils souffrent néanmoins de certaines limitations. La principale est qu'elles ne fournissent qu'une prédiction ponctuelle plutôt qu'une prédiction probabiliste (Bishop et al 2000). Pour s'attaquer aux limites de la SVM, Tipping (Tipping, 2001) a formulé la machine à vecteur de pertinente RVM « Relevance Vector Machine », qui a la même forme fonctionnelle que la SVM mais fournit une distribution prédictive complète. La RVM est une technique d'apprentissage automatique qui utilise l'inférence bayésienne pour obtenir des solutions clairsemées de régression, est utilisée par (Tzikas et al., 2006). La machine à vecteur de pertinence (RVM) est une méthode d'intelligence artificielle permettant d'apprendre les modèles de dégradation des machines à partir des données disponibles au lieu de construire des modèles statistiques (Yan et al., 2013). Elle peut traiter les problèmes de pronostic de machines complexes dont le processus de dégradation est difficile à corrélérer par le modèle statistique (Widodo & Yang, 2011). De plus, la méthode de prédiction de la RUL basée sur la RVM donne également un intervalle de confiance pour fournir une estimation de l'incertitude et une signification de la probabilité. Par conséquent, la RVM a attiré de plus en plus d'attention dans la prédiction de les

RULs des machines (Chen et al., 2020; Kong et al., 2019). Le vecteur de pertinence de la RVM est clairsemé et les hyperparamètres sont simples, ce qui est bénéfique pour la prédiction en ligne de la durée de vie utile restante (Chang & Fang, 2019).

Actuellement, la RVM est présente dans le domaine du pronostic des machines industrielles. Saha and Goebel (Saha & Goebel, 2008) ont appliqué la méthode RVM pour concevoir le modèle de dégradation prédictive des données de batterie lithium-ion. Wang et al (Wang et al., 2012) l'ont utilisé pour estimer les RULs des moteurs à turbine dans le cadre du concours de l'ensemble des données de la NASA « PHM'08 ». Di Maio et al (Di Maio et al., 2012) ont estimé les RULs des roulement partiellement dégradés en combinant la régression exponentielle et la RVM. Hu & Tse (Hu & Tse, 2013) ont proposé un modèle basé sur la RVM pour prédire les RULs des turbines de pompes. Voisin et al (Voisin et al., 2013) ont utilisé cette méthode pour créer un modèle prédictif basé sur des enregistrements d'unités similaires d'une flotte d'unités hétérogènes.

Plus récemment, Zhang (Zhang et al., 2021) ont proposé un schéma de prédiction combinant un indicateur de santé basé sur un réseau de structure hybride d'apprentissage en profondeur constitué d'un réseau neuronal convolutif (CNN) et réseau à mémoire courte terme (LSTM) et une nouvelle machine à vecteurs de pertinence RVM amélioré par un modèle de régression polynomiale pour estimer la durée de vie utile restante d'un roulement. La méthode proposée a été validée à travers l'ensemble des données publiques PRONOSTIA de IEEE PHM'12 challenge (Nectoux et al., 2012) .

## **2.4 CONCLUSION**

Les approches basées sur l'expérience, basée sur les modèles, guidée par les données et hybride sur lesquelles repose le PHM industriel ont d'abord été présentés dans ce chapitre. Leurs avantages et inconvénients ont été énumérés et une méthodologie de choix s'en est suivi. Au préalable, les notions nécessaires au pronostic ont été définis. Ensuite un état de l'art des travaux sur le pronostic guidé par les données a été réalisé.

A travers cette revue, on constate que parmi les méthodes de l'intelligence artificielle, les réseaux de neurones artificiels (ANN) sont les plus répandus, dans les travaux utilisant les ensembles de données de la NASA (PHM'08 data challenge dataset, C-MAPSS dataset), pour leurs avantages reconnus. Cependant, ils ont leurs propres limites.

Par rapport aux ANN, les SVM et RVM sont supérieurs pour traiter les problèmes de petites tailles d'échantillons. Ainsi, ils peuvent être plus adaptés aux problèmes de prédiction de RULs où

seules des mesures limitées sont disponibles. Ceci dit, les performances des SVM et RVM dépendent fortement des fonctions du noyau sélectionnées.

D'autre part, la méthode RVM a l'avantage de fournir une distribution prédictive complète plutôt que ponctuelle comme le fait la machine à vecteurs supports SVM (Support Vector Machine). Aussi les travaux de comparaison de Geobel et al (Goebel et al., 2008) entre la régression par processus gaussien (GPR), les réseaux de neurones artificiels (ANN) et la machine à vecteur de pertinente (RVM) ont montré que les erreurs d'estimation de la RUL par la méthode RVM sont moindre . C'est cette méthode de pronostic que nous adoptons dans la suite de nos travaux.

## Chapitre 3: Méthodologie théorique

---

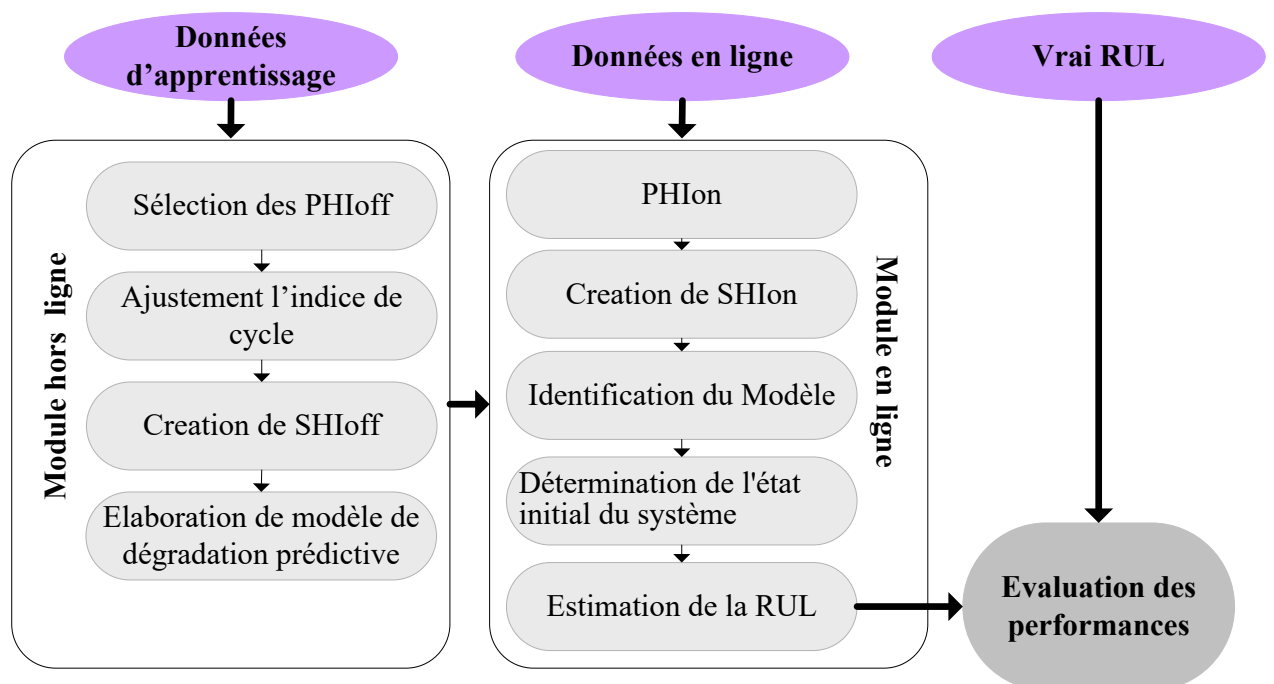
3.1	<u>Introduction</u> .....	55
3.2	<u>Méthodologie de mise en œuvre du pronostic guidé par les données</u> .....	55
3.2.1	<u>Processus hors ligne</u> .....	56
	<u>Génération de l'indice de santé synthétisé</u> .....	57
	<u>Élaboration du modèle de dégradation prédictif</u> .....	59
	<u>Modèle RVM</u> .....	60
3.2.2	<u>Processus en ligne</u> .....	63
	<u>Identification du modèle IM</u> .....	63
	<u>Détermination de l'état initial du système</u> .....	64
	<u>Prédiction de la durée de vie utile restante</u> .....	64
3.2.3	<u>Mesures de performance</u> .....	66
	<u>Score</u> .....	66
	<u>Root Mean Square Error (RMSE)</u> .....	67
	<u>Exactitude</u> .....	67
3.3	<u>Conclusion</u> .....	68

### 3.1 INTRODUCTION

Dans ce chapitre nous présentons en détail la méthodologie théorique de mise en œuvre du pronostic guidé par les données adoptées dans cette thèse. La technique adoptée est celle de la machine à vecteurs de pertinence (RVM : Relevance Vector Machine). Sa mise en œuvre repose sur deux modules essentiels, un module hors ligne et un module en ligne. Le premier module est constitué de quatre étapes, tandis que la seconde est constituée de cinq étapes. Au final une étape d'évaluation des performances de la prédiction de la durée de vie résiduelle (RUL) permet de valider ou d'invalider l'algorithme. Toutes ces étapes sont détaillées dans les sections suivantes.

### 3.2 METHODOLOGIE DE MISE EN ŒUVRE DU PRONOSTIC GUIDE PAR LES DONNEES

L'approche du pronostic guidée par les données est adaptée à tout type d'application instrumentée dans laquelle la connaissance des mécanismes de dégradation est directement intégrée dans les données. La Figure 3.1 présente la méthodologie, adoptée, de mise en œuvre du pronostic guidé par les données dont l'évolution future de la dégradation est déterminée grâce à une méthode statistique associée à une méthode de l'intelligence artificielle. Afin de prédire la durée de vie résiduelle (RUL), la méthodologie adoptée repose sur deux modules essentiels, le module hors ligne et le module en ligne qui sont détaillé dans les sections suivantes.



*Figure 3.1 Méthodologie de mise en œuvre du pronostic guidée par les données*

### 3.2.1 Processus hors ligne

Le processus hors ligne vise à créer un modèle de dégradation du système en utilisant ses données d'apprentissage hors ligne. Ces données sont des mesures de capteurs qui sont souvent la source d'information la plus solide et la plus fiable pour comprendre les phénomènes de dégradation. Ce type d'approche vise à apprendre à travers le phénomène de dégradation, et à saisir les relations subtiles entre les données, même si ces relations sont inconnues ou difficiles à décrire. Ils reposent donc sur l'utilisation de données de surveillance issues de capteurs appelés indice de santé physique (PHI) « Physics Health Index » (Xi et al., 2014).

*Les indices de santé sont des signaux construits soit à partir des données brutes, soit à partir des caractéristiques extraites. L'objectif étant d'aboutir à des descripteurs portant suffisamment d'information pour révéler l'état de santé du composant.*

Ce type d'indice de santé nécessite une compréhension approfondie de la physique des défaillances des composants industriels. En général, le PHI utilise un signal physique dominant comme mesure de santé directe. Dans la littérature, la plupart des pratiques d'ingénierie PHM sont basées sur divers PHI. Par exemple, le signal vibratoire a été utilisé pour caractériser l'état de santé d'un roulement (Gebrael et al., 2005); l'impédance radiofréquence a été utilisée pour le pronostic de la dégradation de joints de soudure électroniques (Kwon et al., 2008) ; la valeur d'impédance de la batterie a été utilisée pour surveiller l'état de santé de batteries d'application spatiale (Saha et al., 2008) ; la capacité de l'enroulement du stator du générateur a été utilisée pour la détection et le pronostic de barres humides pour les générateurs à turbine refroidis par eau (Inoue et al., 2003), etc. Tout comme les exemples mentionnés ci-dessus, lorsque les signaux sensoriels sont directement liés à la physique des défaillances, il est simple d'utiliser le PHI pour extraire l'état de santé du système conçu. Autrement, l'application du PHI est limitée. On s'attend à ce que la mise en correspondance d'une multitude de signaux sensoriels hétérogènes pour un signal physique dominant devienne de plus en plus difficile avec la complexité croissante des systèmes d'ingénierie et des réseaux de capteurs embarqués.

Les PHI sont traités afin d'en extraire des caractéristiques reflétant le comportement du système et sa dégradation. Et donc la sélection des données de capteurs la plus pertinente est la première étape dans cette méthodologie.



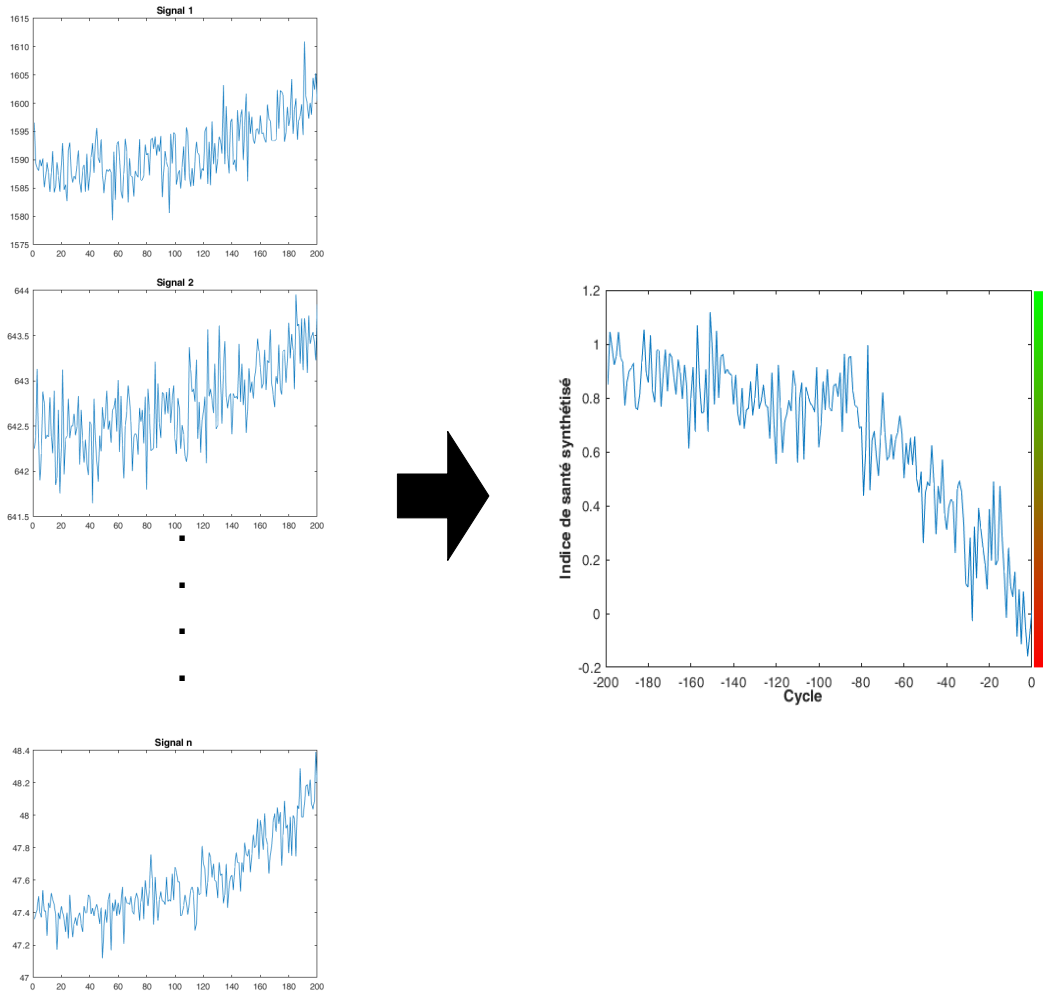
### ***Génération de l'indice de santé synthétisé***

Afin de détecter un défaut naissant (par exemple, une usure ou une fissure) à son stade précoce et suivre son évolution dans le temps jusqu'à défaillance, des indicateurs caractérisant l'état de santé du système, ou de l'un de ses composants doivent être construits. A cet effet, il est nécessaire d'appliquer la surveillance de l'état de fonctionnement en utilisant les données collectées à partir des capteurs. Ces données contiennent des informations brutes sur l'état de santé du système. Par conséquent, en général, les données collectées nécessitent un traitement minutieux pour construire des indicateurs de santé appropriés et sensibles. L'utilisation de l'indice de santé physique (PHI) devient complexe, surtout en présence d'une multitude de signaux hétérogènes. Afin de surmonter cette complexité, l'indice de santé synthétisé (SHI : Synthetized Health Index) est proposé (Abid, 2020; Khelif et al., 2014; Malhotra et al., 2016; Ramasso, 2014; Wang et al., 2012).

La construction de l'indicateur de santé (SHI) est l'une des étapes primordiales pour réaliser le pronostic. Il peut caractériser les performances du système (par exemple, l'énergie produite pour une éolienne), ou il peut représenter les conditions de fonctionnement du système (par exemple, la température, les vibrations, la densité d'huile). En général, le SHI permet de suivre l'état de santé d'un composant ou d'un système au fil du temps. Lorsque l'évolution du SHI commence à augmenter (ou à diminuer) dans le temps, une dérive apparaît des conditions de fonctionnement nominales (normales) vers la défaillance.

Le principal avantage de l'indice de santé synthétisé (SHI) est de formaliser la méthode de caractérisation normalisée d'un système complexe par la combinaison et la transformation des multiples signaux physiques appropriés. Différentes techniques de traitement du signal peuvent être utilisées pour définir les signaux physiques les plus significatifs et créer le SHI. Le SHI est alors délimité dans l'intervalle [0-1] de sorte que "1" et "0" représentent respectivement l'état sain et l'état défectueux (Figure 3.2).

Plusieurs méthodes peuvent être utilisées dans le cadre du pronostic guidée par les données pour construire l'indice de santé synthétique et gérer les différents types de signaux, tels que les données sensorielles continues, discrètes ou binaires. La méthode de transformation linéaire des données est adaptée aux signaux sensoriels collectés en continu (Huang et al., 2015; Schmolck & Everson, 2007; Xi et al., 2014).



**Figure 3.2** Illustration de construction d'un SHI

Supposons qu'il y ait deux groupes de données capteurs multidimensionnelles représentant le système en condition défectueuse et saine, respectivement : la matrice  $Q_0$  de  $M_0 \times N$  et la matrice  $Q_1$  de  $M_1 \times N$  où  $M_0$  et  $M_1$  sont les données respectives pour l'état défectueux et sain du système et  $N$  est la dimension de chaque ensemble donné. En utilisant ces deux matrices, une matrice de transformation  $T$  ( $N \times 1$ ) peut être obtenue pour transformer les signaux multidimensionnels en un SHI unidimensionnel comme suit :

$$T = (Q^T Q)^{-1} Q S_{off} \quad (3.1)$$

Où  $Q = [Q_0; Q_1]^T$ ,  $S_{off} = [S_0; S_1]^T$ ,  $S_0$  est un vecteur nul  $1 \times M_0$  et  $S_1$  est un vecteur unitaire  $1 \times M_1$ .

La matrice  $T$  peut transformer un ensemble de signaux multidimensionnels au temps  $t$  provenant de l'apprentissage hors ligne  $Q_{off}$  ou du processus de prédiction en ligne  $Q_{on}$ , en un SHI normalisé tel que

$$SHI_{off}(t) = Q_{off}.T \quad (3.2)$$

Ou

$$SHI_{on} = Q_{on}.T \quad (3.3)$$

Le SHI est variant entre 0 et 1. Ce SHI contient des signatures de santé extraites des signaux multidimensionnels permettant de construire un modèle prédictif de dégradation dans le processus d'apprentissage hors ligne, ainsi que dans le processus en ligne.

La transformation des signaux physiques multidimensionnels en un SHI unidimensionnel est un processus de fusion d'informations, qui permet d'obtenir une mesure unifiée utilisée pour caractériser le système de santé de l'état. Ainsi, afin d'utiliser le SHI dans la prédiction, il doit caractériser à la fois le processus de dégradation du système et la similarité du processus de dégradation des différentes unités du système surveillé.

Ce SHI peut être utilisé pour construire des courbes de dégradation prédictives de l'état de santé dans le processus de formation hors ligne, ainsi que dans le processus de prédiction en ligne.

### ***Élaboration du modèle de dégradation prédictif***

Après l'étape de construction du SHI, différentes techniques peuvent être utilisées pour élaborer le modèle prédictif de dégradation, telles que les méthodes mentionnées au chapitre 2. Dans les applications de pronostic en temps réel, l'efficacité et la capacité à gérer les incertitudes font partie des intérêts et des préoccupations des chercheurs. En effet, la tâche de traitement des données de la prédiction de la RUL (Remaining Useful Life) en présence de la nature incertaine des signaux multidimensionnels peut être extrêmement longue.

L'apprentissage bayésien épars (SBL : Sparse Bayesian Learning) (Rasmussen & Williams, 2006), en particulier, la technique de la machine vectorielle de pertinence (RVM) (Bishop & Nasrabadi, 2006; Huang et al., 2015; Voisin et al., 2013) a été utilisé dans ce travail afin d'élaborer le modèle de dégradation.

Le SBL est utilisé pour créer l'état de forme statistique du système basé sur la connaissance, tel que l'évolution du modèle de dégradation des composants étudiés.


Le SBL est un modèle linéaire généralisé sous forme bayésienne. Il partage la même forme fonctionnelle que la machine vectorielle (SVM). Comme mentionner au chapitre 2, la SVM (Kapoor & Ohri, 2016; Li et al., 2017) est une technique d'apprentissage automatique généralisée utilisant une combinaison linéaire de fonctions centrales centrées sur un sous-ensemble de données hors ligne, appelé vecteurs de support. Malgré son succès, la SVM souffre d'une limitation critique car elle prédit des points et non des statistiques (voir la section 2.3.3).

Pour surmonter cette limitation, Tipping (Tipping, 2001) a utilisé un modèle linéaire généralisé sous une forme bayésienne, appelé la Relevance Vector Machine. La RVM (Tzikas et al., 2006; Voisin et al., 2013) donne une précision comparable aux machines d'apprentissage SVM et fournit également une distribution prédictive complète avec beaucoup moins de fonctions noyaux.

Les modèles RVM sont basés sur la formulation bayésienne d'un modèle linéaire, mais dont la distribution a priori sur les poids a été modifiée pour aboutir à une sélection automatique des éléments pertinents de la base d'apprentissage. Le modèle de régression RVM commence par le concept de modèle linéaire, qui est couramment utilisé dans une multitude de problèmes de régression.

### **Modèle RVM**

Étant donné certaines mesures cibles  $h = (h_1, h_2, \dots, h_N)$  et certaines entrées  $t = (t_1, t_2, \dots, t_N)$  (Figure 3.3), la relation de régression générale entre les vecteurs cibles et d'entrées peuvent être décrits par un modèle  $f(t_i)$  avec un bruit  $\varepsilon_i$  (Tzikas et al., 2006):



**Figure 3.3** Les solutions possibles de la fonction  $f(t)$

La question qui se pose : ***Quelle solution choisir ?***

Le problème général de régression consiste à déterminer la relation fonctionnelle  $f(t)$ . L'apprentissage automatique « Machine Learning » est la solution proposer dans notre méthodologie, son objectif est d'utiliser un ensemble d'apprentissage pour « apprendre (learn) » une fonction  $f(t)$  qui « explique » correctement les observations/cibles  $h$  étant donné les données d'entrée  $t$ , et donc de déterminer ou d'estimer cette relation fonctionnelle entre la condition souhaitée et les autres conditions du système à partir d'un ensemble d'exemples appariés ou d'observations de ces mêmes conditions (Wang et al., 2013).

$$h(t) = f(t) + \varepsilon(t) \quad (3.4)$$

$\varepsilon(t)$  est la mesure du bruit.

L'algorithme RVM est un modèle probabiliste qui a été défini initialement pour la régression. La fonction de prédiction obtenue est de la forme :

$$h(t) = \sum_{I=1}^N \omega_i \Phi(t, t_i) + \varepsilon(t) \quad (3.5)$$

Où  $\omega = \{\omega_1 \dots \omega_N\}$  vecteurs de poids et les fonctions de base sont formées par les fonctions noyaux  $\Phi(t, t_i)$  centrées sur les points d'apprentissage  $t = \{t_1, \dots, t_N\}$ . La propriété « pertinente » permet la sélection automatique d'un noyau approprié à chaque emplacement par la taille de tous les noyaux non pertinents. Une distribution à priori de sur le vecteur de paramètre de poids  $\omega_i$  pertinent peut être attribuée, de telle sorte qu'un écart différent sur chaque paramètre peut être affecté à chaque poids:

$$p(\omega|\alpha) = \prod_i^M N(\omega_i|0, \alpha_i^{-1}) \quad (3.6)$$

Où  $\alpha_i$  représente la précision du paramètre  $\omega_i$  correspondant, et  $\alpha = (\alpha_1, \dots, \alpha_M)^T$  désigne le vecteur composé de M hyperparamètres, qui sont traités comme des variables indépendantes.

Tipping (Tipping, 2001) s'appuie ici sur la détermination de la pertinence automatique (ARD : Automatic Relevance Determination) proposée par Mackay (Tipping, 2001), dont le principe revient à éliminer les paramètres qui ne permettent pas de définir la solution. Ainsi, pour chaque coefficient  $\omega$  de la fonction de décision, le Prior associe est un hyperparamètre dont la valeur évolue durant la phase d'optimisation. En suivant le principe du rasoir d'Occam (Tipping, 2001), les paramètres éliminés en priorité sont ceux qui ne contribuent pas à maximiser la densité

de probabilité des paramètres selon l'ensemble des données. Ainsi, les paramètres qui ajoutent une complexité trop importante et ne permettent pas de maximiser de manière globale la densité de probabilité sont éliminés de la solution. L'ensemble de vecteurs qui permet généralement de construire la solution est alors suffisante pour définir l'ensemble des points.

Pour spécifier ce modèle d'inférence hiérarchique bayésienne, les distributions à priori pour un  $\alpha$  doivent être définies. Pour un hyperparamètre d'échelle ( $\alpha_i$ ), il est courant d'utiliser une distribution antérieure Gamma tel que :

$$p(\alpha_i) = \text{Gamma}(\alpha_i, b_i) \quad (3.7)$$

Où  $a_i$  et  $b_i$  sont les hyperparamètres et initialement fixés à une distribution Gamma. Le poids antérieur  $p(\omega)$  peut être obtenu en intégrant les hyperparamètres :

$$p(\omega) = \int p(\omega|\alpha) p(\alpha) d\alpha \quad (3.8)$$

En supposant une indépendance, un bruit gaussien de moyenne nulle, de variance  $\beta^{-1}$ , c-à-d.  $\varepsilon \sim N(0, \beta^{-1}I)$  où  $I$  est une matrice identifiée, la vraisemblance des données observées est obtenue comme :

$$p(h|\omega, \alpha, \beta) = N(h|\phi \omega, \beta^{-1}I) \quad (3.9)$$

Où  $\phi$  est soit une  $N \times N$  ou une  $N \times (N \times M)$  matrice de noyau pour les cas simples et multi-noyau, respectivement. Cette matrice formée par toutes les fonctions de base évaluées à tous les points d'apprentissage, à savoir, i.e.,  $\phi = [\phi(t_1), \dots, \phi(t_N)]$  telle que :

$$\phi(t_i) = [\phi(t_1 - t_i), \dots, \phi(t_{i-1} - t_i), \phi(t_{i+1} - t_i), \dots, \phi(t_N - t_i)] \quad (3.10)$$

Pour faire des prédictions en utilisant le modèle bayésien, le paramètre de distribution postérieur  $p(\omega, \alpha, \beta | h)$  doit être calculé. Toutefois, cette distribution postérieure ne peut être calculée analytiquement en raison de sa complexité et donc des approximations doivent être faites par la décomposition de la distribution postérieure et en employant des méthodes d'optimisation itérative appropriées, telles que l'optimisation de la probabilité marginale, l'algorithme d'espérance-maximisation (EM : Expectation Maximization), etc.

Ce schéma SBL peut être appliqué sur l'ensemble des données d'indice de santé dans le module hors ligne d'apprentissage pour construire une base de connaissance de l'état de dégradation du système surveillé consistant en un ensemble de courbes de prédiction de

dégradation (Takata et al., 2004) dont chacun est représenté sous une forme statistique, comme indiqué à l'équation (3.5).

La précision du modèle RVM-SBL dans la représentation des données SHI affecte la précision de la prédiction de la RUL. Afin d'évaluer cette précision, l'erreur quadratique moyenne (RMSE, Root Mean Square Error) correspondante est calculée par :

$$RMSE = \sqrt{\frac{1}{L_{off}} \sum_{i=1}^{L_{off}} (h_i(t_i) - SHI_{off}(t_i))^2} \quad (3.11)$$

### 3.2.2 Processus en ligne

Le module en ligne est divisé en deux grandes étapes distinctes. Dans la première étape, la détermination de l'état initial du système est subdivisée en cinq actions : sélection les  $PHI_{on}$ , création du SHI en ligne ( $SHI_{on}$ ), identification des modèles, initialisation du temps de dégradation ( $T_0$ ) et calcul de la RUL projeté ( $RULp$ ). La deuxième étape est l'étape finale et consiste à prédire la durée de vie utile restante (RUL).

Dans la première étape, les mêmes données hors ligne seront sélectionnées dans le module en ligne pour obtenir les indices de santé physique en ligne ( $PHI_{on}$ ). Ces derniers sont générés à partir des signaux des capteurs des unités du module en ligne. En se basant sur la matrice de transformation Eq (3.1), les données multidimensionnelles en ligne sont transformées en séries unidimensionnelles  $SHI_{on}$ , selon le même principe que le  $SHI_{off}$ .

#### **Identification du modèle IM**

L'étape d'identification du modèle est réalisée pour chaque état de santé d'unité en ligne avec le modèle prédictif de dégradation approprié à l'aide de la méthode de l'erreur quadratique moyenne (RMSE). Au début,  $\varepsilon_i$  est calculé en minimisant la RMSE entre l'indice de santé synthétisé en ligne ( $SHI_{on}(t_j)$ ) et chaque point des modèles prédictifs sur l'axe temporel  $h_i(j)$ , équation (3.13). Chaque unité en ligne identifie ensuite son modèle approprié quand  $\varepsilon_i$  atteint sa plus petite valeur, équation (3.12). Pour une unité en ligne, le modèle d'identification (IM) est donné par :

$$IM = \operatorname{argmin} (\varepsilon_i) \quad (3.12)$$

Ou

$$\varepsilon_i = \min \sqrt{\frac{1}{L_{on}} \sum_{j=1}^{L_{on}} (SHI_{on}(t_j) - h_i(t_j))^2} \quad (3.13)$$

### ***Détermination de l'état initial du système***

Les composants et les unités du système testés dans le processus de prédiction en ligne peuvent avoir des conditions de santé initiales différentes, en raison de la variabilité de la fabrication ou des durées de vie différentes. Ainsi, la détermination des conditions de santé initiales pour les unités constituantes est d'une grande importance pour la prédiction d'une RUL précise. Le modèle de dégradation prédictive ( $h(t)$ ) en tant que la connaissance de base de l'état de santé sera utilisée pour déterminer un état de santé initial à l'échelle du temps ( $T_0$ , ou âge initial) qui est un état temporel avec ajustement optimal entre les données de l'indice de santé synthétique en ligne  $SHI_{on}$  et la courbe de dégradation prédictive ( $h_{IM}(t)$ ).

L'équation (3.14) détermine le cycle initial  $T_0$  avec l'ensemble des données de test dans lequel l'erreur quadratique moyenne entre  $SHI_{on}$  et son modèle approprié ( $h_{IM}$ ) atteint une valeur minimale tout au long de l'axe du temps dans le modèle hors ligne.

$$T_0 = \underset{t}{\operatorname{argmin}} \sqrt{\frac{1}{L_{on}} \sum_{j=1}^{L_{on}} (SHI_{on}(t_j) - h_{IM}(T_0 - t_j))^2} \quad (3.14)$$

$N$  est le nombre de données en ligne.

Nous supposons que  $L_{on} < L_{off}$  (respectivement, durée de vie en ligne, et durée de vie hors ligne correspondant à une courbe de dégradation prédictive hors ligne. A la fin de cette étape, après avoir déterminé  $T_0$ , la durée de vie restante projetée ( $RUL_p$ ) du processus en ligne sur la courbe de dégradation  $h(t_j)$  peut être calculée comme suit :

$$RUL_p = L_{off} - L_{on} - T_0 \quad (3.15)$$

### ***Prédiction de la durée de vie utile restante***

Plusieurs méthodes ont été utilisées pour la prédiction de la durée de vie résiduelle. Wang et al. (Wang et al., 2008) ont utilisé une distance euclidienne afin de trouver les modèles de dégradation les plus similaires à l'actuel qui sont utilisés pour l'estimation des RULs tandis que la RUL finale est calculée à l'aide d'une moyenne pondérée des RULs calculées. Sa méthode a été appliquée à un ensemble de données de moteur d'avion.

Certains autres travaux appliquent la méthode des k plus proches voisins (KNN : k-nearest neighbors) pour trouver les Health Index (HI) similaires à partir de la bibliothèque des modèles de



dégradations. Les HI sélectionnés sont représentés comme les voisins les plus proches selon la métrique de la distance (Ramasso et al., 2012). Mosallam et al. (Mosallam et al., 2016) ont utilisé la méthode KNN afin de trouver les trajectoires d'apprentissage hors ligne les plus similaires à celles en ligne, tandis qu'un filtre bayésien discret récursif est appliqué pour l'estimation de la RUL.

Zio et al. (Zio & Di Maio, 2010) ont appliqué un concept d'analyse de similarité floue par points afin de faire correspondre leurs données actuelles aux données de la bibliothèque de modèles de référence. Ensuite, les RULs des modèles de référence sélectionnés sont agrégés à l'aide d'une moyenne pondérée pour l'estimation finale de la RUL.

Dans cette dernière étape qui est la prédiction de la durée de vie utile restante (RUL), notre attention s'est portée sur la technique d'interpolation basée sur la similarité (SBI : Similarity Based Interpolation), considérée comme la technique privilégiée à ce stade (Wang et al., 2013; Wang et al., 2012).

Les approches basées sur la similarité utilisent également un grand nombre de séquences a priori de défaillance (bibliothèque de modèles de dégradation) pour un ensemble de composants dans différentes conditions de fonctionnement. Cette catégorie d'approches nécessite la surveillance de l'état de santé actuel ou de l'indicateur de santé du système (composant) en ligne. Ensuite, la séquence  $SHI_{on}$  est comparée à la bibliothèque de trajectoires ou modèle de dégradation. Le but est de sélectionner les modèles de dégradation similaires (évolution de la dégradation) qui correspondent le mieux, en termes de similarité ou de proximité, à l'évolution de dégradation du composant actuel. Les modèles de dégradation sélectionnés sont utilisés pour prédire la RUL du composant actuel.

Cette similarité est évaluée par une mesure de la distance entre le modèle prédictif de dégradation  $h$  et l'indice de santé synthétisé  $SHI_{on}$ . Cette différence montre les poids de la similarité ( $W$ ) entre les modèles de dégradation hors ligne (données d'apprentissage) et les indice de santé synthétisé en ligne (données testes). Elle est exprimée ci-dessous comme une somme d'erreurs quadratiques :

$$W_i = \left[ \sum_{j=1}^N \left( SHI_{oni}(t_j) - h_i(t_j) \right)^2 \right]^{-1} \quad (3.16)$$

La RUL prédictive d'un système en ligne est une fonction d'interpolation linéaire en termes de RUL projetées ( $RUL_{p_i}$  pour  $i=1\dots k$ ) sur les modèles hors ligne.

La RUL prédictive des données en ligne peut être exprimée

comme

$$RUL = \frac{1}{W} \sum_{i=1}^k (W_i RUL_{p_i}) \quad (3.17)$$

Où  $W = \sum_{i=1}^K W_i$

### 3.2.3 Mesures de performance

Il est nécessaire de pouvoir juger de la qualité du pronostic afin de décider d'action adéquates. Dans ce sens, plusieurs métriques de performance objectives sont utilisées dans ce travail, notamment la fonction de score, l'erreur quadratique moyenne (RMSE, *Root Mean Square Error*), et la mesure d'exactitude (*Accuracy*) qui sont décrits en détail dans ce qui suit.


#### *Score*

C'est la fonction asymétrique utilisée par de nombreux chercheurs, voir (Saxena et al., 2008), pour évaluer leur algorithme. L'intervalle  $I = [-10, +13]$  est une plage d'acceptabilité définie pour mesurer la qualité des estimations.

$$S_i = \begin{cases} e^{-\left(\frac{d_i}{13}\right)} - 1, & d_i < 0 \\ e^{\left(\frac{d_i}{10}\right)} - 1, & d_i \geq 0 \end{cases} ; S = \frac{1}{N} \sum_{i=1}^N S_i \quad (3.18)$$

Où  $d_i = RUL_{iEstimée} - RUL_{iVrai}$ , N est le nombre d'unité.

Cette métrique évalue les performances en tant que pourcentage de prédictions correctes. L'avantage de cette mesure est qu'elle pénalise davantage les prédictions tardives ( $d_i < -10$ ) que les prédictions précoces ( $d_i \geq 13$ ) (Figure 3.4). Ceci est bénéfique car les prédictions RUL tardives sont plus dangereuses que les prédictions précoces car elles pourraient entraîner des retards des opérations de maintenance nécessaires à la machine. Cependant, l'inconvénient est qu'une seule estimation aberrante (telle qu'une prédiction très tardive) dominerait le score de performance global. Par conséquent, un seul score d'évaluation ne peut pas représenter pleinement les performances de l'algorithme.



**Figure 3.4** Intervalle de performance

Les mesures d'évaluation favorisent les prédictions précoces car elles sont plus tolérables dans les pronostics. Cependant, le score donne un aperçu de l'erreur globale alors que la performance reflète la précision de l'algorithme.

### **Root Mean Square Error (RMSE)**

L'erreur quadratique moyenne (*Root Mean Square Error*) de la RUL estimée par rapport à vrai RUL a été utilisée pour évaluer les performances de l'algorithme. Le RMSE a un poids égal à la fois à la prédiction précoce et tardive de la RUL. Par conséquent, le RMSE produit une meilleure évaluation globale des performances de l'algorithme d'estimation de cette RUL. Plus la valeur de RMSE est petite, plus le résultat du pronostic sera meilleur. Le RMSE peut être obtenu comme suit

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N d_i^2} \quad (3.19)$$

### **Exactitude**

L'exactitude mesure la proximité de la date de défaillance prévue par rapport à la date de défaillance actuelle. Le calcul de cette métrique représente un point critique dans le processus de pronostic. La fonction exponentielle est utilisée ici pour donner une courbe lisse décroissante de façon monotone. L'exactitude est grande, proche de 1 lorsque la valeur attendue est la même que la valeur actuelle et diminue lorsque la valeur attendue s'écarte de la valeur actuelle.

$$E = \frac{1}{N} \sum_{i=1}^N e^{-\left| \frac{d_i}{RUL_{i\text{vrai}}} \right|} \quad (3.20)$$

### 3.3 CONCLUSION

Dans le processus de pronostic proposé, la base de connaissance construite hors ligne s'avère être primordiale car c'est sur ce module que s'appuie la prédiction en ligne de la durée de vie résiduelle (RUL) du système surveillé. Une des étapes clé du pronostic guidé par les données est le passage des indices de santé physiques (PHI : Physics Health Index), provenant des signaux capteurs multidimensionnels, aux indices de santé synthétiques (SHI : Synthetized Health Index) unidimensionnels.

Dans le processus hors ligne, il est très important d'acquérir des connaissances de santé de base statistiquement riches, qui peuvent tenir compte de la variabilité de la fabrication et de l'incertitude de fonctionnement. La méthode de la machine à vecteurs de pertinence (RVM : Relevance Vector Machine) permet de gérer efficacement ces connaissances, en particulier en présence de signaux massives et hétérogènes, afin de pouvoir prédire la RUL en temps réel, avec le plus d'exactitude, dans le processus de prédiction en ligne.

Après avoir détaillé les dix étapes constituant la méthodologie proposée de mise en œuvre du pronostic guidé par les données dans ce chapitre, nous avons procédé à son implémentation dans le chapitre suivant à travers des données expérimentales.

# Chapitre 4: Méthodologie expérimentale

4.1	<u>Introduction</u> .....	70
4.2	<u>Présentation des données</u> .....	70
	4.2.1 <u>Type de moteurs</u> .....	70
	4.2.2 <u>Données traitées</u> .....	71
4.3	<u>Etude de cas 1 - PHM'08 challenge</u> .....	75
	4.3.1 <u>Module hors ligne - Résultats et discussions</u> .....	77
	<u>Sélection du PHIOff</u> .....	77
	<u>Ajustement l'indice de cycle</u> .....	77
	<u>Création du <b>SHIOff</b></u> .....	78
	<u>Elaboration du modèle de dégradation prédictif</u> .....	79
	4.3.2 <u>Module en ligne - Résultats et discussions</u> .....	80
	<u>Création du SHIon</u> .....	80
	<u>Détermination de l'état initial du moteur</u> .....	80
	<u>Prédiction de la RUL</u> .....	82
4.4	<u>Etude de cas 2 – C-MAPSS</u> .....	82
	4.4.1 <u>Module hors ligne – Résultats et discussions</u> .....	83
	<u>Sélection du PHIOff</u> .....	83
	<u>Création du <b>SHIOff</b></u> .....	83
	<u>Elaboration du modèle de dégradation prédictif</u> .....	84
	4.4.2 <u>Module en ligne -Résultats et discussions</u> .....	85
	<u>Création du SHIon</u> .....	85
	<u>Identification du modèle</u> .....	86
	<u>Détermination de l'état initial du turboréacteur</u> .....	86
	<u>Prédiction de la RUL</u> .....	88
	4.4.3 <u>Évaluation des performances</u> .....	89
	<u>Mesures des performances</u> .....	89
	<u>Comparaison des performances</u> .....	90
4.5	<u>Conclusion</u> .....	91

## 4.1 INTRODUCTION

Le pronostic est encore plus difficile que le diagnostic, ce qui est l'une des principales raisons pour lesquelles il est encore considéré comme un élément émergeant du PHM. Certaines défaillances sont intermittentes et donc difficiles à prévoir. Par conséquent, il n'existe toujours pas de méthodologie universellement acceptée pour les pronostics (Lee et al., 2014). Bien qu'il s'agisse d'une partie très difficile du PHM, le pronostic est également l'un de ses aspects les plus bénéfiques.

Dans ce chapitre nous allons démontrer l'efficacité de la méthodologie générique proposée, de mise en œuvre du pronostic, à travers l'implémentation de deux études de cas. Les données des deux cas traités proviennent de centre PCoE de la NASA Ames Research Center et concernent les dégradations de moteurs turboréacteurs.

La première étude, désignée « PHM'08 », nous a permis de développer l'algorithme proposé. Mais sans pouvoir effectuer d'évaluation de ses performances ni de validation en raison de l'absence, dans ce cas d'étude, de valeurs vraies des RULs.

Par contre, la seconde étude, désignée « C-MAPSS », nous a permis non seulement d'implémenter toutes les étapes de l'algorithme proposé, mais aussi d'effectuer l'évaluation de ses performances, ainsi que sa validation grâce à la présence, dans ce cas d'étude, des valeurs vraies des RULs des cent turboréacteurs traités.


## 4.2 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. Nous avons implémenté notre méthodologie sous Matlab et plus précisément en utilisant sa boîte à outils Sparse Bayes.

### 4.2.1 Type de moteurs

Ces données concernent la dégradation de moteurs turboréacteurs à double chambres de combustion (Figure 4.1), avec une poussée pouvant atteindre 90000 lb, une altitude pouvant atteindre un niveau inférieure à celui de la mer allant jusqu'à 42,000 ft et nombre de Mach de 0 à 0.9 (tableau 4.2). Dans ce type de moteurs, l'air aspiré par le ventilateur est comprimé en deux étapes en passant par des compresseurs basses et hautes pressions (HPC et LPC). Après cela, dans

la chambre de combustion, l'air comprimé est chauffé pour produire suffisamment de poussée pour entraîner les turbines basses et haute pression (LPT et HPT). La puissance de poussée sera produite à la fois par l'air produit par le ventilateur dans le flux de dérivation et par l'air entrant dans le cœur du moteur. Dans la suite de ce travail les moteurs pourront être indifféremment désignés par turboréacteurs ou unités.



-Fan

- LPC : Low Pressure Compressor (compresseur basse pression)

HPC : High Pressure Compressor (Compresseur haute pression)

- N1 : Turbine axis (axe turbine)

N2 : Turbine shaft (arbre turbine)

HPT : High Pressure Turbine (turbine à haute pression)

LPT : Low-Pressure Turbine (turbine à basse pression)

**Figure 4.1** Moteurs turboréacteurs de C-MAPSS (Abhinav Saxena & Kai Goebel, 2008)

#### 4.2.2 Données traitées

L'ensemble des données C-MAPSS se compose de cinq sous-ensembles de données, nommés FD001, FD002, FD003, FD004, et PHM'08 challenge datasets (tableau 4.1). Les quatre premiers sous-ensembles de données contiennent des données d'apprentissage et de test ainsi que les valeurs RUL réelles des données de test. Par contre, l'ensemble des données utilisé dans le cadre du PHM Challenge'08 ne contient pas de valeurs RUL réelles.

Dans ce cinquième ensemble de données, les utilisateurs doivent entraîner leurs algorithmes à l'aide des données d'apprentissage du fichier `train.txt`. Ils doivent ensuite évaluer les performances de prédiction de leurs RULs sur des données fournies dans le fichier `test.txt`. Les

vraies valeurs de RUL associées ne sont pas révélées comme dans l'ensemble des données (C-MAPSS). Les utilisateurs pourront utiliser une application web (A Saxena & K Goebel, 2008) pour télécharger leurs résultats et obtenir un retour sur leur score global. Une fois les algorithmes entraînés obtiennent satisfaction, les utilisateurs peuvent les appliquer à l'ensemble des données du test final contenu dans le fichier nommé `final_test.txt`. Les utilisateurs doivent envoyer le vecteur des RULs pour l'ensemble du test final à la Société PHM pour évaluation. Un score sera envoyé en retour. Les chercheurs sont encouragés à publier leurs résultats, quelle que soit la performance absolue, s'ils estiment que leur algorithme présente une nouveauté. L'objectif étant de développer des approches innovantes pour le pronostic.

**Tableau 4.1** Descriptions des ensembles de données C-MAPSS et PHM'08

Datasets		#Condition	#unités d'apprentissage	#unités de test	#RUL
C-MAPSS dataset	#FD001	1	100	100	100
	#FD002	6	260	259	259
	#FD003	1	100	100	100
	#FD004	6	249	248	248
PHM'08 challenge dataset	#5	6	218	218	Non
	Final test	6	218	435	Non

Les ensembles de données se composent de plusieurs séries chronologiques multivariées. Chaque ensemble de données est ensuite divisé en sous-ensembles d'apprentissage (train) et de test. Chaque série temporelle provient d'un moteur différent provenant d'un parc de moteurs du même type. Chaque moteur commence par différents degrés d'usure initiale et de variation de fabrication qui sont inconnus de l'utilisateur. Cette usure et cette variation sont considérées comme normales, c'est-à-dire qu'elles ne sont pas considérées comme un défaut. Il existe trois paramètres opérationnels, tableau 4.2, qui ont un effet substantiel sur les performances du moteur. Ces paramètres sont également inclus dans les données. Les données sont contaminées par les bruits des capteurs.

Le moteur fonctionne normalement au début de chaque série temporelle et développe un défaut à un moment donné de la série. Dans l'ensemble des données d'apprentissage, le défaut



prend de l'ampleur jusqu'à la défaillance du système. Dans l'ensemble des données de test, la série temporelle se termine quelque temps avant la défaillance du système. L'objectif étant de prédire le nombre de cycles opérationnels restants avant défaillance pour l'ensemble des données de test.

Les données d'apprentissage et de test pour chaque cycle par moteur comprennent l'identification du moteur, l'indice de cycle, trois valeurs pour un contexte opérationnel et vingt-et-une valeur de mesure de capteur (Tableau 4.2 et Tableau 4.3). Les données de capteurs sont fournies sous forme de fichier texte compressé au format zip avec 26 colonnes de nombres, séparées par des espaces, tableau (4.3).

Pour chaque échantillon, le moteur fonctionne normalement, mais il s'arrête immédiatement lorsqu'un défaut survient. Dans l'ensemble des données de test, l'index de cycle se termine avant que le système ne tombe en panne. Le but de ces données collectées est d'estimer les RULs et d'évaluer la précision des prédictions en utilisant différentes métriques.

Concernant les sous-ensembles qui ont une seule condition de fonctionnement, cela signifie que le moteur fonctionne au niveau de la mer. En revanche, les six conditions de fonctionnement des autres sous-ensembles ne sont pas révélées dans la description de l'ensemble des données.

**Tableau 4.2** Descriptions des réglages opérationnels

<b>Paramètre opérationnel</b>		
<b>No.</b>	<b>Description</b>	<b>Intervalle</b>
1	Altitude	0-42 Kft
2	Vitesse en Ma (Nombre de mach)	0 – 0.84
3	Angle TRA (Throttle Resolver Angle)	20 - 100

**Tableau 4.3** Descriptions des mesures des capteurs

<b>Mesures de capteurs</b>			
<b>No</b>	<b>Symbole</b>	<b>Description</b>	<b>Unité</b>
1	<b>T2</b>	Température totale à l'entrée du ventilateur	°R
2	<b>T24</b>	Température totale à la sortie du LPC	°R
3	<b>T30</b>	Température totale à la sortie du HPC	°R
4	<b>T50</b>	Température totale à la sortie du LPT	°R
5	<b>P2</b>	Pression à l'entrée du ventilateur	Psia
6	<b>P15</b>	Pression totale dans le conduit de dérivation	Psia
7	<b>P30</b>	Pression totale à la sortie HPC	Psia
8	<b>Nf</b>	Vitesse physique du ventilateur	rpm
9	<b>Nc</b>	Vitesse physique de corps du moteur	rpm
10	<b>Epr</b>	Pression relative du moteur (P50/P2)	-
11	<b>Ps30</b>	Pression statique de la sortie HPC	Psia
12	<b>Phi</b>	Débit relative de carburant à Ps30	pps/psi
13	<b>NRf</b>	Vitesse du ventilateur corrigée	rpm
14	<b>NRc</b>	Vitesse de base corrigée	rpm
15	<b>BPR</b>	Écoulement relative	-
16	<b>farB</b>	Taux de du carburant – air dans le brûleur	-
17	<b>htBleed</b>	Enthalpie de saignement	-
18	<b>Nf-dmd</b>	Vitesse du ventilateur demandée	rpm
19	<b>PCNfR_dmd</b>	Vitesse du ventilateur corrigée demandée	rpm
20	<b>W31</b>	Purge du liquide de refroidissement HPT	lbm/s
21	<b>W32</b>	Purge du liquide de refroidissement LPT	lbm/s

**Tableau 4.4** Descriptions des données des capteurs

1	2	3	4	5	6	7	8		25	26
1	1	10.0047	0.2501	20.0	489.05	604.13	1499.45		28.58	17.1735
1	2	0.0015	0.0003	100.0	518.67	642.13	1584.55		38.99	23.3619
1	3	34.9986	0.8401	60.0	449.44	555.42	1368.17		14.83	8.8555
1	4	20.0031	0.7005	0.0	491.19	607.03	1488.44		24.42	14.7832
1	5	42.0041	0.8405	40.0	445.00	549.52	1354.48		10.99	6.4025
1	6	20.0032	0.7017	0.0	491.19	607.37	1480.46	...	24.44	14.7019
:	:	:	:	:	:	:	:		:	:
:	:	:	:	:	:	:	:		:	:
1	221	0.0008	0.0000	100.0	518.67	643.88	1593.26		38.67	23.0218
1	222	20.0003	0.7001	0.0	491.19	608.00	1494.99		24.28	14.5645
1	223	34.9992	0.8400	60.0	449.44	556.60	1385.96		14.70	8.6695

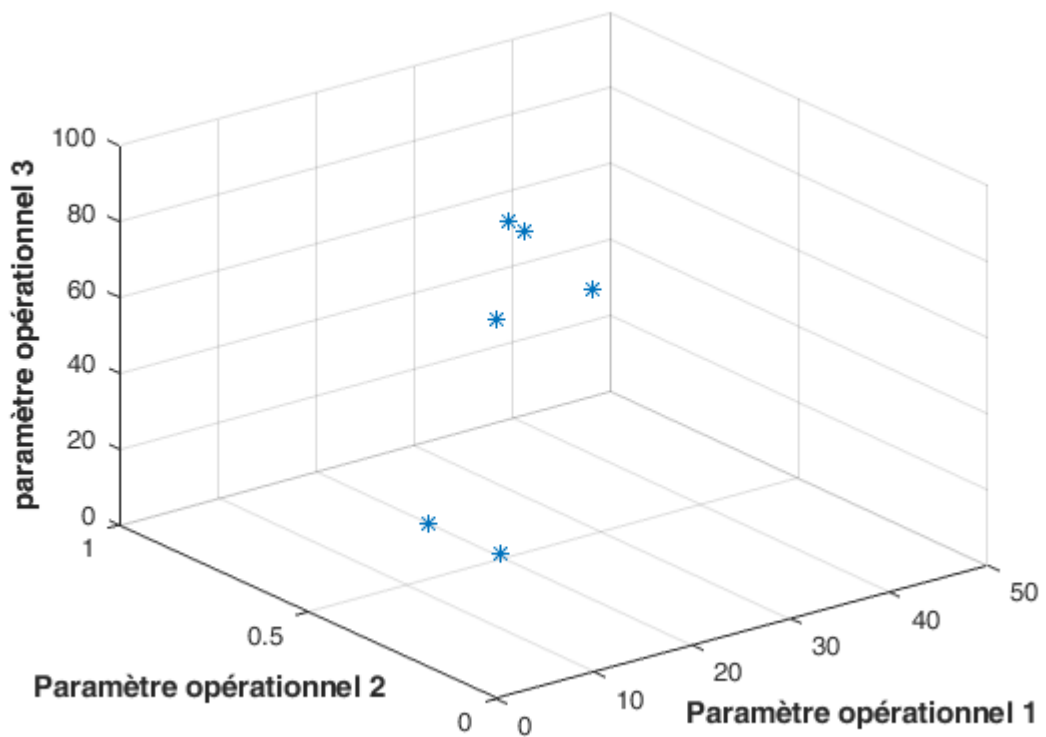
### 4.3 ETUDE DE CAS 1 - PHM'08 CHALLENGE

Les signaux des capteurs ont été obtenus à partir de 218 unités de moteur hors ligne, de sorte que le nombre d'ensembles de données d'entraînement est de 4578 (21x218) au total (Motrani & Noureddine, in press).

Il a été constaté que trois paramètres opérationnels ont un effet substantiel sur les comportements de dégradation du moteur et entraînent six régimes de fonctionnement différents, comme indiqué dans le tableau 4.5. Ces régimes sont présentés dans la Figure 4.2. Par des six points qui sont en fait six groupes hautement concentrés qui contiennent chacune des milliers de points d'échantillonnage. Ce qui indiquent six conditions de fonctionnement discrètes du système.

**Tableau 4.5 Régimes opérationnels**

Régime	Paramètre opérationnel 1	Paramètre opérationnel 2	Paramètre opérationnel 3
1	0	0	100
2	20	0.25	20
3	20	0.7	0
4	25	0.62	80
5	35	0.84	60
6	42	0.84	40



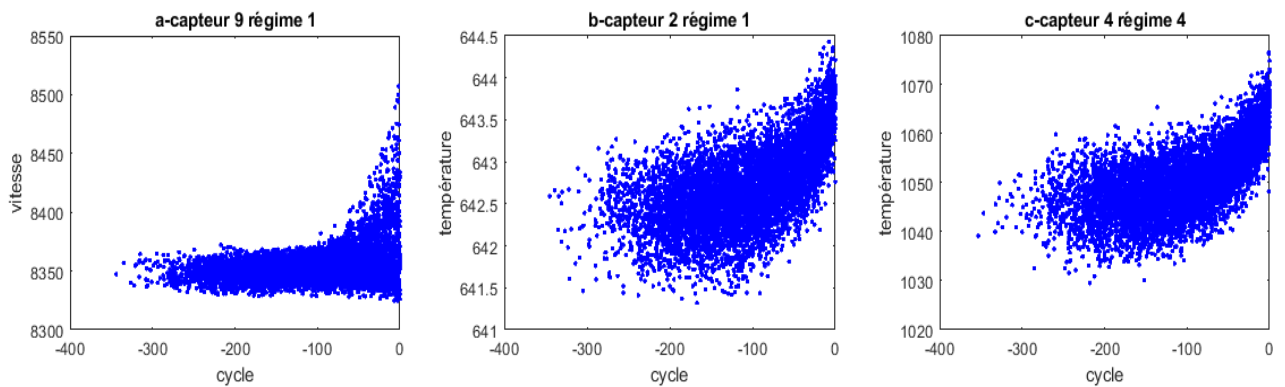
**Figure 4.2 Effet des régimes opérationnels**

### 4.3.1 Module hors ligne - Résultats et discussions

#### *Sélection du PHIOff*

La sélection des données des capteurs commence à partir de l'observation dans chaque régime de fonctionnement. Quelques capteurs ont des valeurs discrètes uniques ou multiples, à partir desquelles il est difficile de trouver une trace de dégradation du système. La plupart des capteurs à valeurs continues présentent une tendance monotone pendant la durée de vie des unités. Cependant, certains d'entre eux montrent des tendances de fin de vie incohérentes parmi les différentes unités dans l'ensemble des données d'apprentissage comme le montre la Figure 4.3 (a).

La Figure 4.3 (a) montre le résultat des dégradations du capteur 9, régime 1, pour toutes les unités. A ces lectures de capteurs, on peut noter que les dégradations sont réparties sur une large plage, rendant la quantification des modes de défaillance plus difficile. Les Figures 4.3 (b) et (c) présentent les dégradations ayant une tendance croissante. Ils concernent respectivement les dégradations issues du capteur 2, régime 1, et du capteur 4, régime 4, pour toutes les unités. Sur l'ensemble des 21 signaux des capteurs observés, seuls sept ont des tendances cohérentes semblables. Par conséquent, ce sont ceux-là que nous avons choisis pour caractériser l'état du moteur, à savoir : les capteurs de température (2, 3, 4), les capteurs de pression (7, 11) et les capteurs de débit (12, 15).



**Figure 4.3** Sélection des signaux - PHM'08

#### *Ajustement l'indice de cycle*

Afin de considérer les différentes conditions initiales, nous avons calculé un indice de cycle ajusté :

$$C_{adj} = C - C_f \quad (4.1)$$

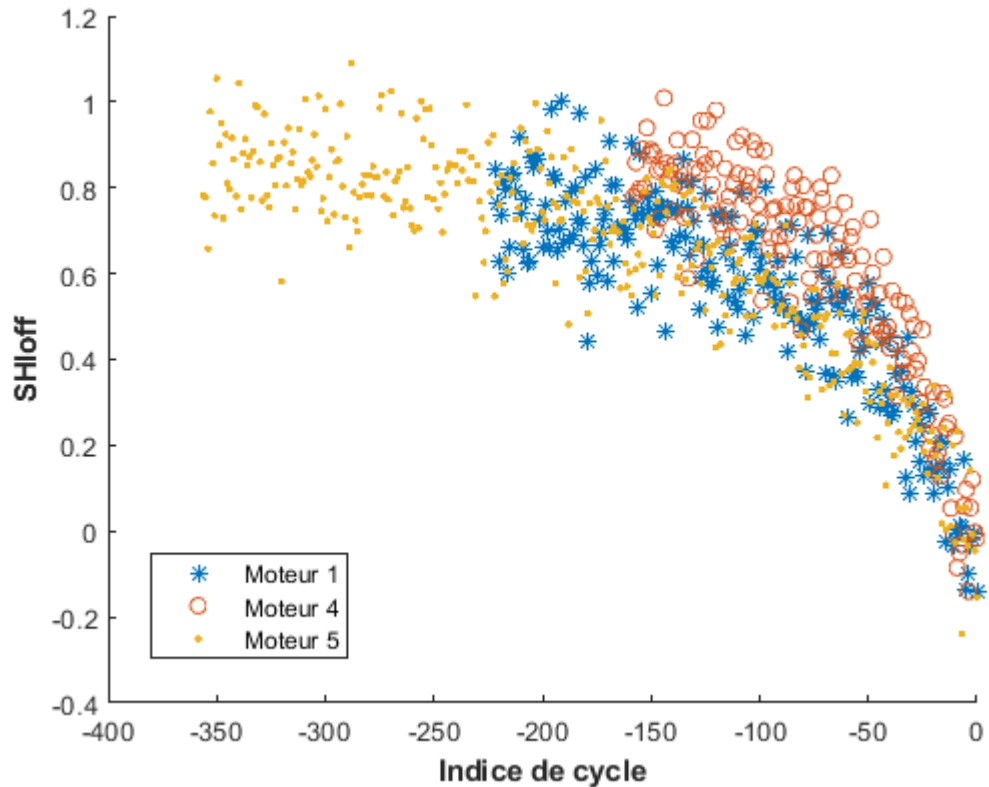
Où  $C$  et  $C_f$  représentent respectivement les cycles de fonctionnement et le cycle défectueux du moteur. Le numéro de cycle 0 indique la panne du moteur tandis que le numéro de cycle négatif correspond à un cycle de fonctionnement avant la panne. En définissant, en référence la panne du moteur comme étant « 0 », il est possible d'afficher clairement et d'utiliser facilement l'état de dégradation des différents moteurs dans l'apprentissage hors ligne avec les types de dégradation différentes.

### **Création du $SHI_{off}$**

Le  $SHI_{off}$  est construit pour représenter le processus d'état de dégradation des moteurs à partir des sept signaux de capteur sélectionnés. Les différentes matrices de transformation  $T_K$  sont construites selon l'Eq. (3.1) pour les six régimes de fonctionnement différents ( $k = 1$  à 6). Pour cela, les différentes matrices  $Q_0$  et  $Q_1$  sont construites respectivement pour ces différents régimes de fonctionnement. Dans ce cas, nous construisons  $Q_0$  avec les données de capteurs représentant l'état de défaillance des moteurs dans lequel l'indice de cycle ajusté est compris entre -4 et 0. En utilisant la même méthode, nous construisons  $Q_1$  avec les données de capteurs représentant l'état sain où l'indice de cycle ajusté est inférieur à -300. Nous avons construit les différentes matrices  $Q_0$  et  $Q_1$  en répétant ce processus pour les six régimes de fonctionnement différents. La matrice de transformation créée  $T$  ( $7 \times 6$ ), où chaque colonne est un vecteur de transformation pour les points de régime de fonctionnement correspondants, est présentée ci-dessous.

$$T = \begin{pmatrix} -0.03352 & 0.00420 & 0.01725 & 0.07551 & 0.04861 & 0.06308 \\ -0.00358 & -0.00571 & -0.01046 & -0.00551 & -0.00720 & -0.01003 \\ -0.0760 & -0.00741 & -0.00624 & -0.00695 & -0.00891 & -0.01105 \\ 0.03902 & 0.06381 & 0.05371 & 0.04381 & 0.05489 & 0.03470 \\ -0.29961 & -0.34434 & -0.30928 & -0.39681 & -0.51199 & -0.50965 \\ 0.07880 & 0.05048 & 0.07701 & 0.06448 & 0.08791 & 0.0163 \\ -0.67360 & -1.36813 & -0.62036 & -2.68974 & -1.25800 & -0.49316 \end{pmatrix} \quad (4.2)$$

La Figure 4.4 représente l'évolution de l'indice de santé synthétisé " $SHI_{off}$ ", obtenu à partir de l'ensemble des données d'entraînement, des 3 moteurs 1, 4 et 5. L'évolution de ces nuages de points décroît logiquement de la valeur 1 (sain) vers la valeur 0 (défaillance) avec des durées de vie différentes. Le moteur 5 affiche la plus grande durée de vie ensuite suivent les moteurs 1 et 4.



**Figure 4.4** Indice de santé synthétisé « $SHI_{off}$ » - PHM'08

#### ***Elaboration du modèle de dégradation prédictif***

Pour l'élaboration du modèle prédictif de dégradation nous avons utilisée l'approche basée sur la technique RVM- SBL avec fonction de base gaussienne, comme étudié au troisième chapitre. Afin de pouvoir estimer la RUL, en ligne, de chaque moteur, nous avons généré pour chacun d'entre eux son modèle prédictif de dégradation. Au total, nous avons obtenu les 218 modèles de dégradation prédictifs correspondants.

Le RMSE correspondant a été calculé, conformément à l'équation (3.11), et la valeur moyenne obtenue est de 0,0034, ce qui prévaut d'une prédiction correcte de la RUL.

La Figure 4.5 représente le modèle de dégradation prédictif résultant du moteur 1.

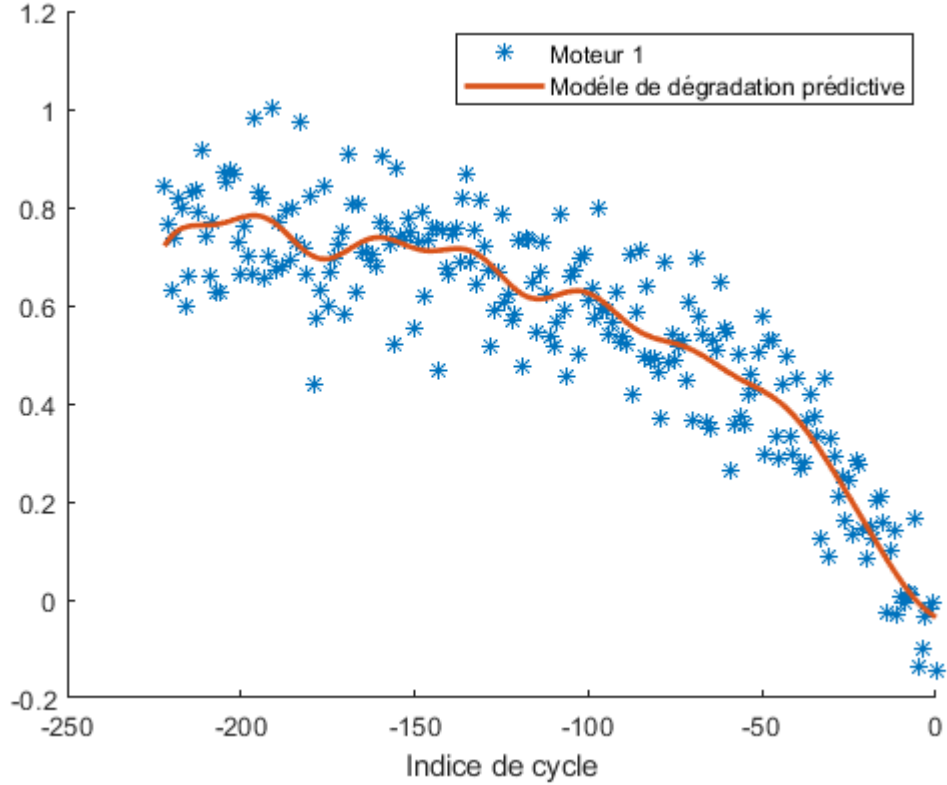


Figure 4.5 Modèle de dégradation prédictif – PHM'08

### 4.3.2 | Module en ligne - Résultats et discussions

#### *Création du SHIon*

Dans le processus en ligne, les données utilisées sont l'ensemble des données de test en ligne correspondantes aux 218 moteurs. Tout d'abord, pour chaque moteur, les 7 signaux en ligne des capteurs (2, 3, 5, 7, 11, 12 et 15) sont utilisés afin de créer le  $SHI_{on}$  via l'Eq. (3.3) en utilisant la matrice de transformation obtenue dans le module hors ligne (Equation 4.2), pour les étapes suivantes.

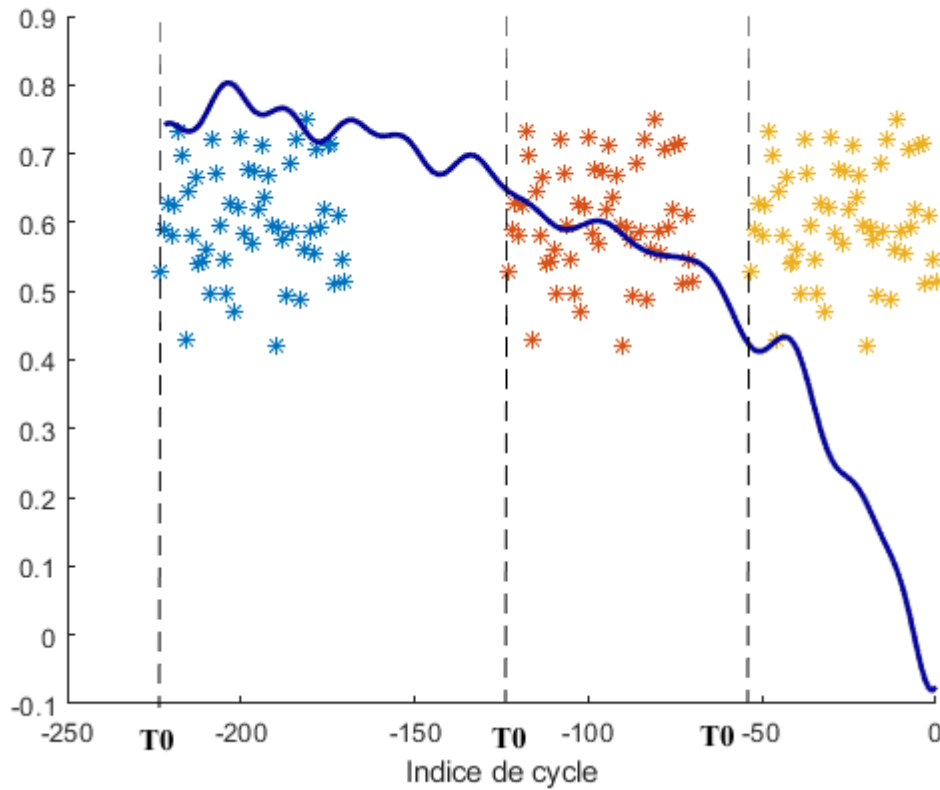
#### *Détermination de l'état initial du moteur*

Puisque l'étape de l'identification du modèle n'était pas utilisée dans cette étude, le temps de dégradation initial  $T_0$  est déterminé, selon l'équation (4.3), avec l'ensemble des données en ligne en réduisant la somme minimale des erreurs quadratiques entre  $SHI_{on}$  et le modèle de dégradation prédictif  $h(t_j)$  tout au long de l'axe du temps dans le modèle hors ligne pour trouver le meilleur état initial à l'échelle de temps ( $T_0$ ).

$$\min_{T_0 \in [0, L_{off} - L_{on}]} \sum_{j=1}^N (SHI_{on}(t_j) - h(T_0 - t_j))^2 \quad (4.3)$$



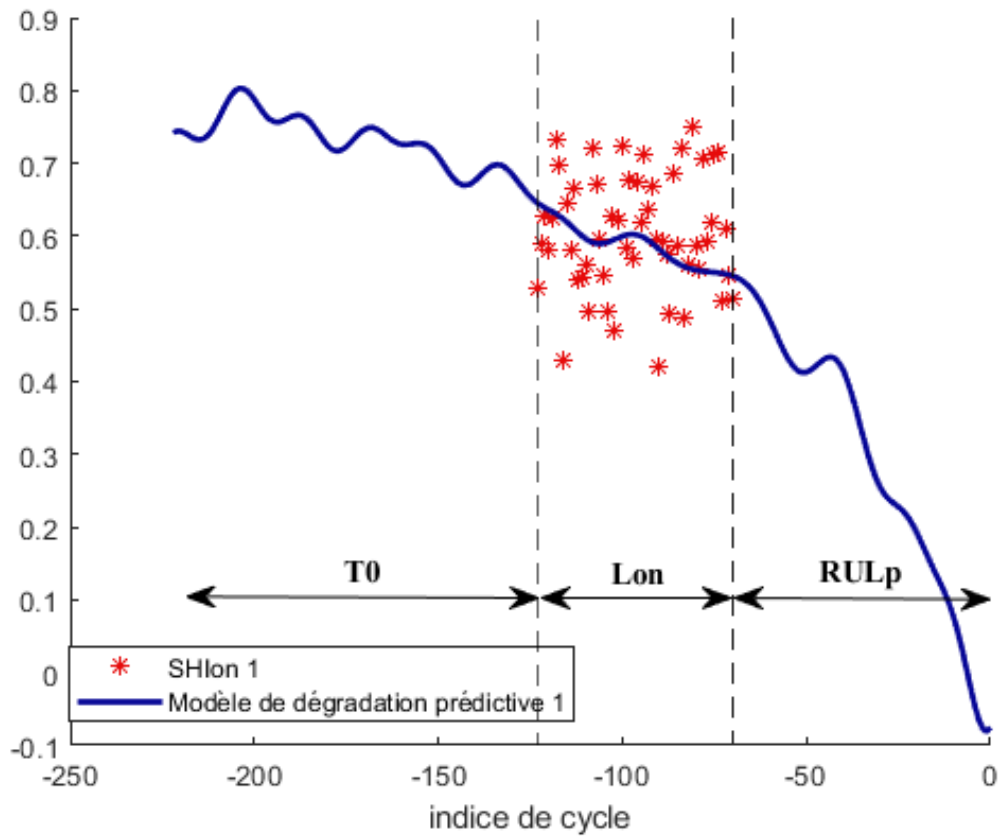
Ainsi, le temps de dégradation initial  $T_0$  pour chaque moteur a été déterminé. La Figure 4.6 illustre la procédure de détermination de  $T_0$ . On constate, dans ce cas, que  $T_0 = -125$  cycles caractérise le plus précisément état de santé initiale du  $SHI_{on}$  du moteur 1.



**Figure 4.6** Procédure de détermination du temps initial  $T_0$  -PHM'08

La durée de vie utile restante prévue  $RUL_p$  en ligne de chaque moteur a été obtenue à partir de l'équation (3.15). La répétition de ce processus a fourni 218  $RUL_p$  projetés sur les 218 modèles prédictifs de dégradation.

La Figure 4.6 illustre les résultats obtenus pour déterminer le temps de dégradation initial ( $T_0$ ) du moteur 1 ainsi que sa  $RUL_p$ , de sorte que les points représentent son  $SHI_{on}$  de l'unité en ligne 1 et la courbe représente son modèle de dégradation prédictif de l'unité 1.



**Figure 4.7** Temps initial  $T_0$  et durée de vie restante projeté  $RUL_p$  – PHM'08

#### **Prédiction de la RUL**

Enfin, la technique SBI a été utilisée pour déterminer les poids de similarité  $W_i$  et la RUL de chaque moteur en utilisant respectivement les équation (3.16) et (3.17).

Les RUL des moteurs 1, 4 et 5, pour exemple, sont respectivement 77, 84 et 21 cycles.

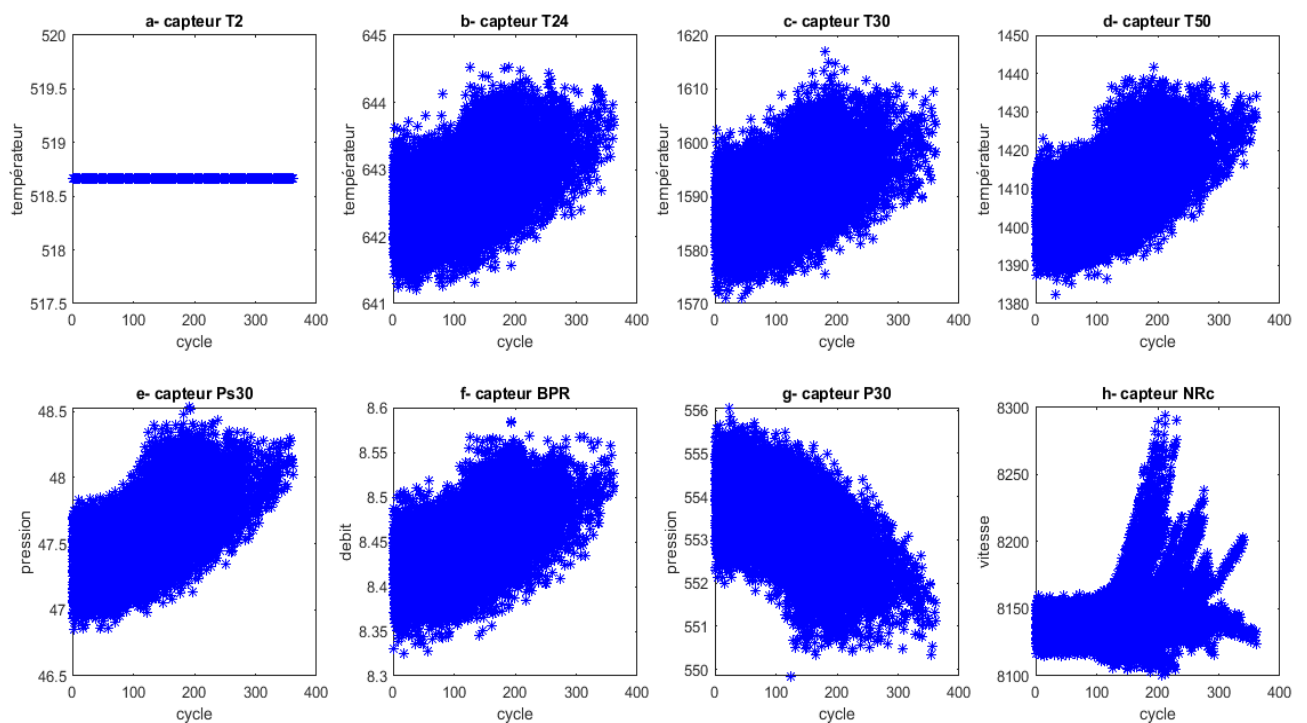
#### **4.4 ETUDE DE CAS 2 – C-MAPSS**

Dans cette étude de cas, nous nous intéressons au groupe de données du 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". La même méthodologie est suivie dans cette seconde étude de cas, mais avec plusieurs améliorations dans l'algorithme ainsi que son évaluation, à travers la métrique « score », en ligne.

#### 4.4.1 Module hors ligne – Résultats et discussions

##### *Sélection du $PHI_{off}$*

Les Figures 4.8 montrent diverses dégradations parmi les 21 signaux des capteurs des données d'apprentissage des 100 turboréacteurs. Dans cette étude, nous avons observé que sept signaux ne contiennent aucune information de dégradation, tel que le capteur T2 (Figure 4.8 a). Parmi les 14 autres signaux, seuls cinq (T24, T30, T50, Ps30 et BPR) présentent des tendances semblables, (Figure 4.8 b, c, d, e et f). Ce sont ces 5 signaux que nous avons retenus pour caractériser l'état de santé des turboréacteurs. Les 9 capteurs restants affichent des informations de dégradation non similaires, tels que les capteurs P30 et NRc (Figure 4.8 g et h).



**Figure 4.8** Sélection des signaux - C-MAPSS


##### *Création du $SHI_{off}$*

La construction du  $SHI_{off}$  permet de représenter l'état de dégradation des turboréacteurs à partir des cinq signaux de capteur retenus et en utilisant une matrice de transformation T. Les matrices de transformation T sont définies selon l'équation (3.1), avec les deux matrices  $Q_0$  et  $Q_1$ .

La matrice de transformation résultante T, de dimension  $(5 \times 1)$ , tel que chaque ligne est un vecteur de transformation pour les points de régime de fonctionnement correspondants, que nous avons obtenu est :

$$T = \begin{pmatrix} 0.1095 \\ -0.0065 \\ -0.0134 \\ -0.5265 \\ -1.8256 \end{pmatrix} \quad (4.4)$$

La Figure 4.9 représente l'évolution du  $SHI_{off}$  obtenu à partir de l'ensemble des données d'apprentissage des 3 turboréacteurs 1, 2 et 8, après avoir déterminés les indices de cycles ajustés. L'évolution de ce nuage de points décroît logiquement de la valeur 1 (sain) vers la valeur 0 (défectueux), avec des durées de vie différentes. Le moteur 2 présente la durée de vie la plus longue, ensuite suivent les turboréacteurs 1 et 8.



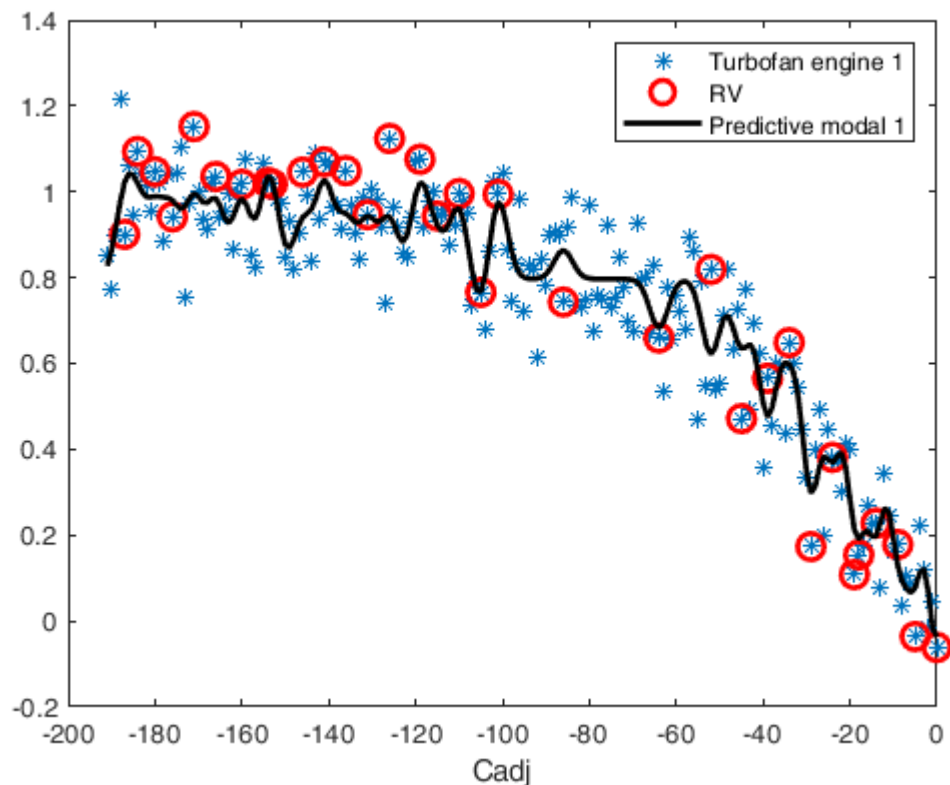
**Figure 4.9** Indice de santé synthétisé « $SHI_{off}$ » - C-MAPSS

#### ***Elaboration du modèle de dégradation prédictif***

La Figure 4.10 représente le modèle prédictif de dégradation du turboréacteur 1. La technique RVM-SBL avec fonction de base gaussienne utilisée a obtenu la courbe de dégradation prédictive avec seulement 32 vecteurs de pertinence (RV : Relevance Vector). Ce prédicteur

RVM-SBL obtient une bonne correspondance avec la courbe exacte de dégradation. Il peut être effectué individuellement pour différentes unités d'apprentissage. La précision du RVM-SBL dans la représentation des données SHI affecte la précision de la prédiction de la RUL. Un modèle plus précis de SBL conduit généralement à une prédiction de RUL plus précise, mais nécessite un effort de calcul plus important. La précision et l'efficacité du SBL ont été intensivement étudiées dans la littérature et les lecteurs intéressés sont dirigés vers la référence (Tipping, 2001) pour plus d'informations.

Le RMSE correspondant a été calculé, conformément à l'équation (3.11), et la valeur moyenne obtenue est de 0.0042 ce qui prévaut d'une prédiction correcte de la RUL.



*Figure 4.10* Modèle de dégradation prédictif – C-MAPSS

#### 4.4.2 Module en ligne -Résultats et discussions

##### *Création du SHIon*

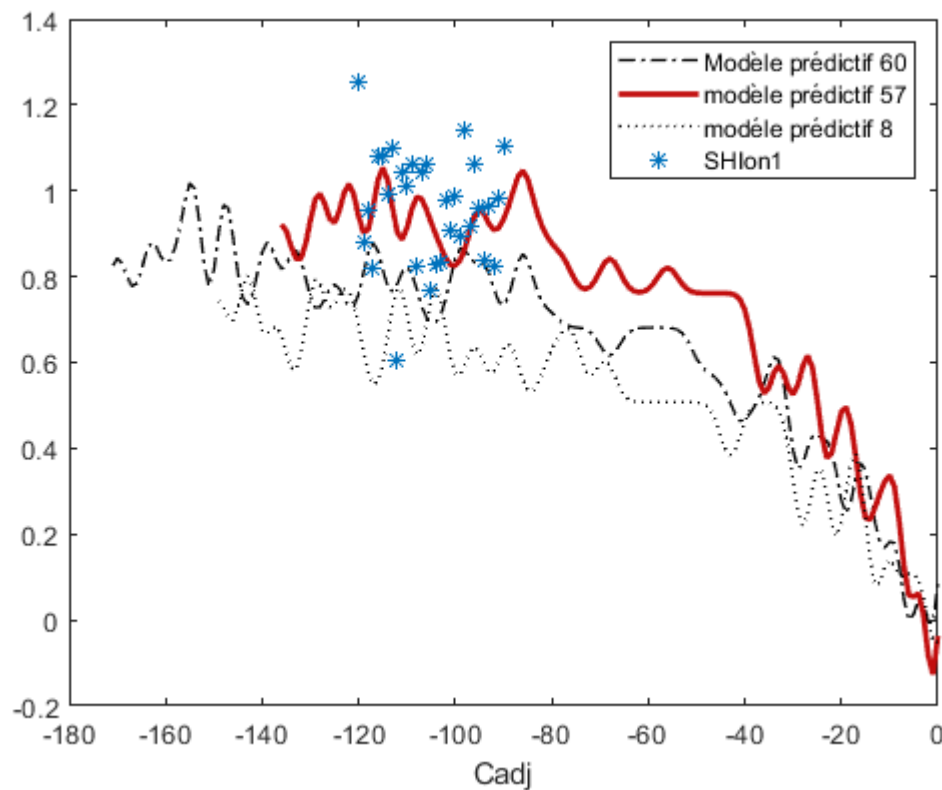
Dans le processus en ligne, l'ensemble des données test\_FD001 en ligne relatives aux 100 turboréacteurs est utilisé. Tout d'abord, et pour chaque moteur, les 5 signaux en ligne des capteurs (T24, T30, T50, Ps30 et BPR) sont utilisés. Ensuite nous créons les  $SHI_{on}$  correspondants, avec

la matrice de transformation de l'équation (4.3), nécessaires pour les tâches suivantes sont utilisés afin de créer le  $SHI_{on}$  via l'Eq. (3.3), pour les étapes suivantes.

### ***Identification du modèle***

Dans cette étude de cas, nous avons développé notre algorithme, par rapport à la version précédente. Ceci nous a permis de passer à l'étape fondamentale, dans ce module, de l'identification du modèle adéquat pour chaque unité, en ligne, pour l'estimation de la RUL.

La Figure 4.11 représente, comme exemple, le meilleur modèle de dégradation de l'unité 1 en ligne. Nous arrivons à cette détermination en utilisant les équations (3.12) et (3.13) qui permettent de calculer le RMSE entre le  $SHI_{on}$  et chaque point des 100 modèles prédictifs : le modèle prédictif de dégradation du turboréacteur 57 est identifié, dans ce cas-là, comme le modèle adéquat de l'unité 1 en ligne, par rapport aux modèles 8 et 60.




***Figure 4.11*** Identification du modèle

### ***Détermination de l'état initial du turboréacteur***

Comme mentionner dans la section 3.2.2, l'initialisation du temps de dégradation  $T_0$  est un point très important pour spécifier la valeur RUL prédictive à l'aide de  $SHI_{on}$ .

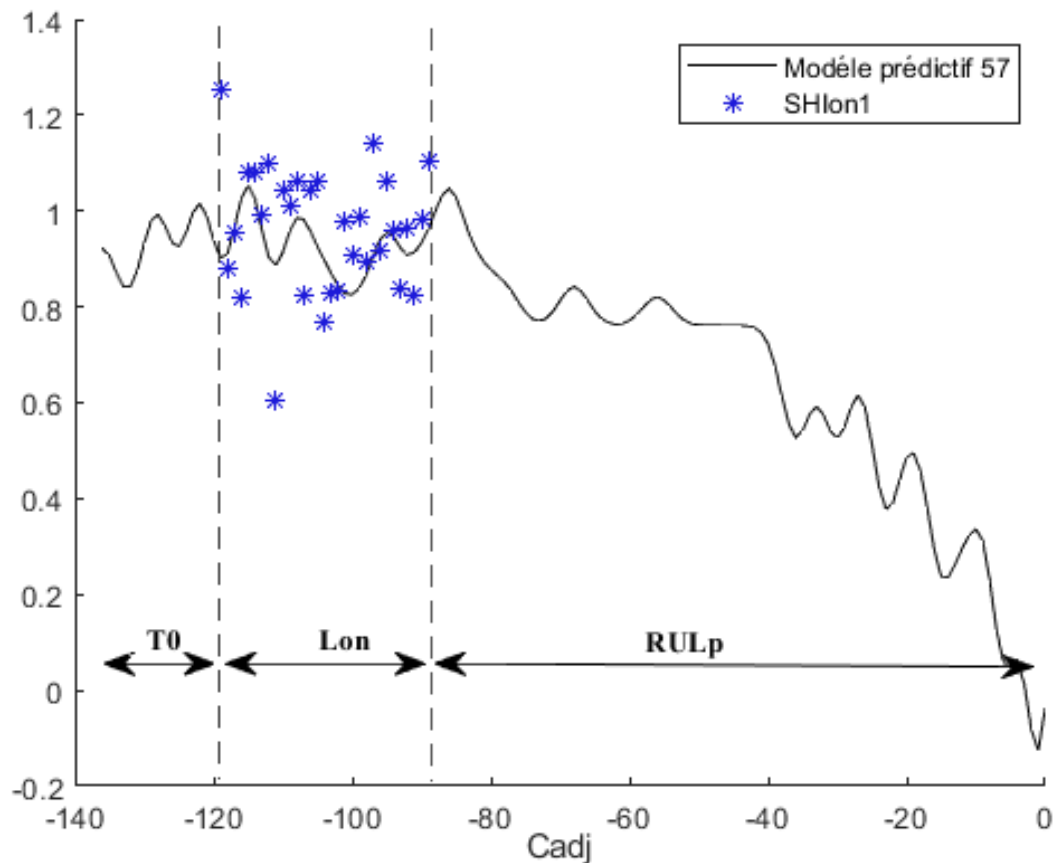
L'équation (3.14) détermine le cycle initial  $T_0$  avec l'ensemble des données de test dans lequel l'erreur quadratique moyenne entre  $SHI_{on}$  et son modèle approprié ( $h_{IM}$ ) atteint une valeur minimale tout au long de l'axe du temps dans le modèle hors ligne.

Ainsi, le temps de dégradation initial  $T_0$  pour chaque turboréacteur est déterminé. Dans le cas du modèle prédictif de dégradation de l'unité 57 avec le  $SHI_{on}$  de l'unité 1 (Figure 4.12),  $T_0 = -119$  cycles caractérise le plus précis état de santé initiale.



**Figure 4.12** Procédure de détermination du temps initial  $T_0$  -C-MAPSS

La Figure 4.13 illustre le temps de dégradation initial  $T_0$  trouvé du turboréacteur 1 ainsi que sa  $RUL_p$ , de sorte que les points représentent son  $SHI_{on1}$ , et la courbe son modèle prédictif de dégradation (modèle 57). Nous obtenons la  $RUL_p$  projeté de chaque moteur en ligne, à l'aide de l'équation (3.15). Par réplication de ce processus, nous avons obtenu les 100  $RUL_p$  projetées sur les 100 modèles prédictifs de dégradation.




**Figure 4.13** Temps initial  $T_0$  et durée de vie restante projeté  $RUL_p$  – C-MAPSS

### **Prédiction de la RUL**

Enfin, nous avons utilisé la technique SBI pour déterminer les poids de similarité  $W_i$ . Dans ce cas, 10 grands poids ont été utilisés pour prédire la RUL de chaque turboréacteur en utilisant respectivement les équations (3.16) et (3.17).

La Figure 4.14 montre le résultat de la procédure SBI correspondante au turboréacteur 1. Les étoiles représentent le  $SHI_{on}$  du turboréacteur 1, et les courbes représentent les modèles prédictifs de dégradation des 10 grands poids sélectionnés.





*Figure 4.14 Interpolation par similarité*

#### 4.4.3 Évaluation des performances

##### *Mesures des performances*

Grâce aux valeurs vraies données des RULs, dans ce cas d'étude C-MAPSS, nous pouvons procéder à l'évaluation des performances de notre algorithme à travers les 3 métriques décrit à la section 3.2.3.

Pour cela, les performances des résultats obtenus (RUL prédites) sont évaluées par rapport aux données d'un fichier RUL\_FD001, qui contient 100 valeurs de la vraie RUL, à travers les équations (3.18), (3.19) et (3.20) respectivement pour la fonction score, l'erreur quadratique moyenne, et la mesure d'exactitude. L'intervalle  $I = [-10, +13]$  est la plage d'acceptabilité retenue pour la métrique score, comme déjà définie à la section 3.2.3.

Les résultats obtenus affichent, tableau 4.5 :

Un score de 7,29, ce qui signifie que notre pronostic est très correct et très acceptable.

Une erreur quadratique moyenne (RMSE) correspondante de 19,74.

Un taux de précision (Exactitude) de 78 %.

**Tableau 4.6** Evaluation de performance

<b>Métrique de Performance</b>	<b>FD_001</b>
<b>Score</b>	7.29
<b>RMSE</b>	19.74
<b>Exactitude</b>	0.78

**Comparaison des performances**

Afin de vérifier et de valider l'exactitude de l'algorithme proposé, nous comparons nos résultats avec les résultats obtenus par Babu et al, Jayasinghe et al, et Zheng et al, respectivement dans les références (Babu et al., 2016 ; Jayasinghe et al., 2018 ; Zheng et al., 2017).

Ils ont utilisés dans leurs travaux, respectivement, les algorithmes TCMN (Temporal Convolutional Memory Networks : réseaux à mémoire convolutive temporelle), Deep LSTM (Deep Long Short-Term Memory : mémoire approfondie court terme), CNN (Conventional Neural Network : réseau de neurone conventionnel, MLP (Multi-Layer Perceptron : perceptron multicouche), SVR (Support Vector Regression : régression vectorielle de support) et RVR (Relevance Vector Regression : régression vectorielle de pertinence), tableau 4.6.

**Tableau 4.7** Comparaison des résultats de score

<b>Référence</b>	<b>Méthode</b>	<b>Score</b>	<b>RMSE</b>
Jayasinghe et al. 2018	TCMN	12.2	23.57
Zheng et al. 2017	Deep LSTM	3.38	16.14
Babu et al. 2016	CNN	12.86	/
	MLP	178	37.56
	SVR	13.81	20.96
	RVR	15.02	23.80
Méthodologie proposée	RVM-SBI	7.29	19.75

En comparaison, les résultats obtenus dans nos travaux, avec l'algorithme RVM-SBI proposé, qui affichent un score de 7,29, s'avèrent être beaucoup plus performant que ceux obtenus par Jayasinghe (2018) et Babu (2016) avec les algorithmes TCMN, CNN, MLP, SVR et RVR, respectivement affichant des scores de 12,2, 12,86, 178, 13,81 et 15,02. Par contre, l'algorithme TCMN de Zheng (2017) présente un meilleur score.

#### 4.5 CONCLUSION

Dans ce chapitre, les différentes étapes de l'approche proposée sont mises en œuvre dans deux études de cas, désignées « PHM'08 » et « C-MAPSS », provenant de la NASA armes Research Center.

Dans l'étude « PHM'08 », le traitement des données des 21 signaux de capteurs surveillant les 218 turboréacteurs concernés a donné les résultats suivants :

- Seuls 7 signaux de capteur ont été sélectionnés, pour leur tendance significative, sur lesquels les indices synthétiques de santé ont été créés.
- Les 218 RULs des moteurs ont été prédites.
- La performance des algorithmes développés n'a pu être évaluée que sur son modèle RVM-SBL (module hors ligne) à travers la métrique RMSE. La valeur moyenne RMSE obtenue, de 0,0034, montre une bonne précision du modèle, indiquant une prédiction correcte des RULs.

Dans l'étude « C-MAPSS », des corrections et améliorations significatives ont été réalisées sur l'algorithme proposé. Pour ne citer que celle-ci, l'étape d'identification du modèle, dans le module en ligne, a été ajoutée, engendrant ainsi une nette augmentation de la précision du pronostic. De plus l'évaluation en ligne et la validation ont été concrétisées.

Concernant les résultats dans ce cas, le traitement des données des 21 signaux de capteurs surveillant les 100 turboréacteurs concernés a donné ce qui suit :

- Seuls 5 signaux de capteur ont été sélectionnés, pour leur tendance significative, sur lesquels les indices synthétiques de santé ont été créés.
- Les 100 RULs des moteurs ont été prédites.
- La performance des algorithmes développés a pu être évaluée sur son modèle RVM-SBI (module en ligne) à travers les 3 métriques : score, RMSE et exactitude. La bonne valeur du

score obtenue, de 7,29, signifie l'acceptation de notre pronostic, avec respectivement un RMSE et une exactitude 19,74 et 78 %.

- La comparaison de nos résultats avec ceux des références (Babu et al., 2016 ; Jayasinghe et al., 2018 ; Zheng et al., 2017) a permis de les valider. En effet, notre algorithme RVM-SBI affiche un score de 7,29, qui s'avère nettement meilleur que les scores de 12,2, 12,86, 178, 13,81 et 15,02 obtenus dans les références citées avec les algorithmes TCMN, CNN, MLP, SVR et RVR, respectivement. Seul le score de 3.38 obtenu par l'algorithme Deep LSTM de Zheng (2017) est meilleur que le nôtre.

## Conclusion générale

L'objectif principal de cette thèse est de fournir une vision complète des approches de pronostic, qui sont indispensables, pour la mise en place de la maintenance basée sur l'état de santé, qui repose sur la surveillance continue des systèmes et l'estimation de la durée de vie utile restante des composants, des équipements et des machines complexes.

De nos jours, les techniques de pronostics guidées par les données sont encore une discipline en pleine évolution qui tend à s'imposer dans des systèmes réels complexes bien cartographiés. L'algorithme de pronostic basé sur les données, reposant sur l'association de l'intelligence artificielle et des méthodes d'interpolation par similarité, développé dans cette thèse, a été utilisé pour prédire les durées de vie utiles restantes (RULs) de turboréacteurs.

Le support méthodologique de l'approche proposée intègre toutes les étapes séquentielles du pronostics basées sur les données réalisé en deux modules distincts, hors ligne et en ligne.

Le processus hors ligne est basé sur 4 étapes : la sélection des capteurs, l'ajustement de l'indice de cycle, la création du SHI et élaboration du modèle de dégradation prédictive. Ce processus permet de concevoir le modèle prédictif de dégradation reposant sur l'algorithme RVM-SBL (Relevance Vector Machin- Sparse Bayesien Learning).

Le processus en ligne est basé sur cinq étapes : la sélection du  $PHI_{on}$ , la création du  $SHI_{on}$ , la détermination de l'état initial du système, l'identification du modèle et la prédiction de la RUL. Ce module a pour but de prédire la durée de vie résiduelle (RUL) en s'appuyant sur l'algorithme d'interpolation basée sur la similarité RVM-SBI (Relevance Vector Machine-Sparse Bayesien Interpolation). La mise en œuvre de la technique a été effectuée dans l'environnement MATLAB en implémentant deux études de cas de dégradation de turboréacteurs, dont les données proviennent des bases de données de la NASA Ames Research Center, libre d'accès.

Les résultats obtenus dans les deux cas d'étude sont synthétisés comme suit :

- Dans la première étude « PHM'08 », nous avons pu prédire, à partir de 7 signaux significatifs de capteurs sélectionnés, les 218 RULs concernées des 218 turboréacteurs surveillés à partir de 21 capteurs.
- La performance des algorithmes développés n'a pu être évaluée que sur son modèle RVM-SBL (module hors ligne). La valeur moyenne RMSE obtenue, de 0,0034, montre une bonne précision du modèle, indiquant une prédiction correcte des RULs.

- Dans la seconde étude « C-MAPSS », des corrections et améliorations significatives ont été réalisées sur l’algorithme proposé. Dans ce cas, nous avons pu prédire, à partir de 5 signaux significatifs de capteurs sélectionnés, les 100 RULs concernées des 100 turboréacteurs surveillés à partir des 21 capteurs.
- La performance des algorithmes développés a pu être évaluée sur son modèle RVM-SBI (module en ligne). La bonne valeur du score obtenue, de 7,29, signifie l’acceptation de notre pronostic, avec respectivement un RMSE et une exactitude 19,74 et 78 % .
- La comparaison de notre score (7.29), avec l’algorithme RVM-SBI proposé, par rapport aux scores de 12,2, 12,86, 178, 13,81 et 15,02, obtenus dans les références citées avec les algorithmes TCMN, CNN, MLP, SVR et RVR respectivement, s’avère nettement meilleur. Il n’est dépassé que par le score obtenu par l’algorithme Deep LSTM (3.38).

Ces résultats permettent de valider nos algorithmes (RVM-SBL et RVM-SBI) et d’affirmer que la méthodologie de pronostic développée dans cette thèse peut être utilisée avec succès pour prédire les durées de vie utiles restantes (RULs) des systèmes.

En perspective, plusieurs aspects peuvent être développés et menés dans des travaux futurs, tels que le développement de ce cadre ou la mise en œuvre d’autres techniques bien identifiées dans cette thèse.

# Bibliographie

---

- Abichou, B. (2013). *Contribution à la formalisation de bilans/états de santé multi-niveaux d'un système pour aider à la prise de décision en maintenance: agrégation d'indicateurs par l'intégrale de Choquet* Université de Lorraine].
- 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].
- Abu-Hanna, A., & Lucas, P. J. (2001). Prognostic models in medicine. *Methods of information in medicine*, 40(01), 1-5.
- Ahmadzadeh, F., & Lundberg, J. (2013). Remaining useful life prediction of grinding mill liners using an artificial neural network. *Minerals Engineering*, 53, 1-8.
- 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.
- Al-Dulaimi, A., Zabihi, S., Asif, A., & Mohammadi, A. (2019). A multimodal and hybrid deep neural network model for Remaining Useful Life estimation. *Computers in Industry*, 108, 186-196.
- Aye, S. A., & Heyns, P. (2017). An integrated Gaussian process regression for prediction of remaining useful life of slow speed bearings based on acoustic emission. *Mechanical Systems and Signal Processing*, 84, 485-498.
- Banks, J., & Merenich, J. (2007). Cost benefit analysis for asset health management technology. 2007 annual reliability and maintainability symposium,
- Barajas, L. G., & Srinivasa, N. (2008). Real-time diagnostics, prognostics and health management for large-scale manufacturing maintenance systems. International Manufacturing Science and Engineering Conference,
- Bechhoefer, E., & Morton, B. (2012). Condition monitoring architecture: To reduce total cost of ownership. 2012 IEEE Conference on Prognostics and Health Management,
- Benkedjough, T., Medjaher, K., Zerhouni, N., & Rechak, S. (2013). Remaining useful life estimation based on nonlinear feature reduction and support vector regression. *Engineering Applications of Artificial Intelligence*, 26(7), 1751-1760.
- Benkedjough, T., Medjaher, K., Zerhouni, N., & Rechak, S. (2015). Health assessment and life prediction of cutting tools based on support vector regression. *Journal of intelligent manufacturing*, 26(2), 213-223.
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4). Springer.
- Byington, C. S., Roemer, M. J., & Galie, T. (2002). Prognostic enhancements to diagnostic systems for improved condition-based maintenance [military aircraft]. Proceedings, iee aerospace conference,
- Caesarendra, W., Widodo, A., & Yang, B.-S. (2011). Combination of probability approach and support vector machine towards machine health prognostics. *Probabilistic Engineering Mechanics*, 26(2), 165-173.
- Carino, J. A., Zurita, D., Delgado, M., Ortega, J., & Romero-Troncoso, R. (2015). Remaining useful life estimation of ball bearings by means of monotonic score calibration. 2015 iee international conference on industrial technology (icit),
- Chang, Y., & Fang, H. (2019). A hybrid prognostic method for system degradation based on particle filter and relevance vector machine. *Reliability Engineering & System Safety*, 186, 51-63.

- Chen, F., Yang, Y., Tang, B., Chen, B., Xiao, W., & Zhong, X. (2020). Performance degradation prediction of mechanical equipment based on optimized multi-kernel relevant vector machine and fuzzy information granulation. *Measurement*, *151*, 107116.
- da Costa, P. R. d. O., Akçay, A., Zhang, Y., & Kaymak, U. (2020). Remaining useful lifetime prediction via deep domain adaptation. *Reliability Engineering & System Safety*, *195*, 106682.
- Deutsch, J., & He, D. (2017). Using deep learning-based approach to predict remaining useful life of rotating components. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, *48*(1), 11-20.
- Di Maio, F., Tsui, K. L., & Zio, E. (2012). Combining relevance vector machines and exponential regression for bearing residual life estimation. *Mechanical Systems and Signal Processing*, *31*, 405-427.
- Dong, H., Jin, X., Lou, Y., & Wang, C. (2014). Lithium-ion battery state of health monitoring and remaining useful life prediction based on support vector regression-particle filter. *Journal of Power Sources*, *271*, 114-123.
- Dong, S., & Luo, T. (2013). Bearing degradation process prediction based on the PCA and optimized LS-SVM model. *Measurement*, *46*(9), 3143-3152.
- Dragomir, O. E., Gouriveau, R., Dragomir, F., Minca, E., & Zerhouni, N. (2009). Review of prognostic problem in condition-based maintenance. 2009 European Control Conference (ECC),
- El Koujok, M. (2010). *Contribution au pronostic industriel: intégration de la confiance à un modèle prédictif neuro-flou* Université de Franche-Comté].
- Elforjani, M. (2016). Estimation of remaining useful life of slow speed bearings using acoustic emission signals. *Journal of Nondestructive Evaluation*, *35*(4), 1-16.
- 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.
- Elsheikh, A., Yacout, S., & Ouali, M.-S. (2019). Bidirectional handshaking LSTM for remaining useful life prediction. *Neurocomputing*, *323*, 148-156.
- Engel, S. J., Gilmartin, B. J., Bongort, K., & Hess, A. (2000). Prognostics, the real issues involved with predicting life remaining. 2000 IEEE Aerospace Conference. proceedings (cat. no. 00th8484),
- Fan, J., Yung, K.-C., & Pecht, M. (2015). Predicting long-term lumen maintenance life of LED light sources using a particle filter-based prognostic approach. *Expert systems with applications*, *42*(5), 2411-2420.
- Fan, J., Yung, K. C., & Pecht, M. (2011). Physics-of-failure-based prognostics and health management for high-power white light-emitting diode lighting. *IEEE Transactions on device and materials reliability*, *11*(3), 407-416.
- Femto-st. (2004). *science & technologies*. <https://www.femto-st.fr/fr>
- Fink, O. (2020). Data-driven intelligent predictive maintenance of industrial assets. In *Women in industrial and systems engineering* (pp. 589-605). Springer.
- Fumeo, E., Oneto, L., & Anguita, D. (2015). Condition based maintenance in railway transportation systems based on big data streaming analysis. *Procedia Computer Science*, *53*, 437-446.
- Gebraeel, N., Lawley, M., Liu, R., & Parmeshwaran, V. (2004). Residual life predictions from vibration-based degradation signals: a neural network approach. *IEEE Transactions on Industrial Electronics*, *51*(3), 694-700.
- Gebraeel, N., & Pan, J. (2008). Prognostic degradation models for computing and updating residual life distributions in a time-varying environment. *IEEE Transactions on reliability*, *57*(4), 539-550.



- Gebraeel, N. Z., Lawley, M. A., Li, R., & Ryan, J. K. (2005). Residual-life distributions from component degradation signals: A Bayesian approach. *IIE Transactions*, 37(6), 543-557.
- Goebel, K., Saha, B., Saxena, A., Mct, N., & Riacs, N. (2008). A comparison of three data-driven techniques for prognostics. 62nd meeting of the society for machinery failure prevention technology (mfpt),
- Gouriveau, R., Medjaher, K., Ramasso, E., & Zerhouni, N. (2013). PHM-Prognostics and health management-de la surveillance au pronostic de défaillances de systèmes complexes. *Techniques de l'Ingénieur*, 9.
- Gouriveau, R., Medjaher, K., & Zerhouni, N. (2017). *Du concept de PHM à la maintenance prédictive 1: Surveillance et pronostic* (Vol. 3). ISTE Group.
- Heimes, F. O. (2008). Recurrent neural networks for remaining useful life estimation. 2008 international conference on prognostics and health management,
- Heng, A., Zhang, S., Tan, A. C., & Mathew, J. (2009). Rotating machinery prognostics: State of the art, challenges and opportunities. *Mechanical Systems and Signal Processing*, 23(3), 724-739.
- Hess, A., Calvello, G., Frith, P., Engel, S., & Hoitsma, D. (2006). Challenges, issues, and lessons learned chasing the "Big P": real predictive prognostics part 2. 2006 IEEE Aerospace Conference,
- 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.
- Hu, J., & Tse, P. W. (2013). A relevance vector machine-based approach with application to oil sand pump prognostics. *Sensors*, 13(9), 12663-12686.
- Hu, Y., Baraldi, P., Di Maio, F., & Zio, E. (2015). A particle filtering and kernel smoothing-based approach for new design component prognostics. *Reliability Engineering & System Safety*, 134, 19-31.
- Huang, H.-Z., Wang, H.-K., Li, Y.-F., Zhang, L., & Liu, Z. (2015). Support vector machine based estimation of remaining useful life: current research status and future trends. *Journal of Mechanical Science and Technology*, 29(1), 151-163.
- Huang, R., Xi, L., Li, X., Liu, C. R., Qiu, H., & Lee, J. (2007). Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods. *Mechanical Systems and Signal Processing*, 21(1), 193-207.
- IMS, C. (2001). <http://www.imscenter.net/IMS>
- Inoue, Y., Hasegawa, H., Sekito, S., Sotodate, M., Shimada, H., & Okamoto, T. (2003). Technology for detecting wet bars in water-cooled stator windings of turbine generators. IEEE International Electric Machines and Drives Conference, 2003. IEMDC'03.,
- ISO13381-1. (2004). Condition monitoring and diagnostics of machines - prognostics - Part1 : General guidelines. *Int. Standard, ISO*.
- ISO13381-1. (2015). Condition monitoring and diagnostics of machines - prognostics - Part1 : General guidelines. *Int. Standard, ISO*.
- IVHMC. (2008). *Integrated Vehicle Health Management Centre*. <https://www.cranfield.ac.uk/centres/integrated-vehicle-health-management>
- Jardine, A. K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483-1510.
- Javed, K. (2014). *A robust & reliable Data-driven prognostics approach based on extreme learning machine and fuzzy clustering* [Université de Franche-Comté].
- Javed, K., Gouriveau, R., & Zerhouni, N. (2014). SW-ELM: A summation wavelet extreme learning machine algorithm with a priori parameter initialization. *Neurocomputing*, 123, 299-307.

- Javed, K., Gouriveau, R., & Zerhouni, N. (2015). A new multivariate approach for prognostics based on extreme learning machine and fuzzy clustering. *IEEE transactions on cybernetics*, 45(12), 2626-2639.
- Javed, K., Gouriveau, R., & Zerhouni, N. (2017). State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels. *Mechanical Systems and Signal Processing*, 94, 214-236.
- Javed, K., Gouriveau, R., Zerhouni, N., & Hissel, D. (2016). Prognostics of proton exchange membrane fuel cells stack using an ensemble of constraints based connectionist networks. *Journal of Power Sources*, 324, 745-757.
- Jayasinghe, L., Samarasinghe, T., Yuenv, C., Low, J. C. N., & Ge, S. S. (2019). Temporal convolutional memory networks for remaining useful life estimation of industrial machinery. 2019 IEEE International Conference on Industrial Technology (ICIT),
- Jin, B., Chen, Y., Li, D., Poolla, K., & Sangiovanni-Vincentelli, A. (2019). A one-class support vector machine calibration method for time series change point detection. 2019 IEEE International conference on prognostics and health management (ICPHM),
- Jouin, M., Gouriveau, R., Hissel, D., Péra, M.-C., & Zerhouni, N. (2016). Degradations analysis and aging modeling for health assessment and prognostics of PEMFC. *Reliability Engineering & System Safety*, 148, 78-95.
- Kadry, S. (2012). *Diagnostics and prognostics of engineering systems: methods and techniques: methods and techniques*. IGI Global.
- Kapoor, N., & Ohri, J. (2016). Fuzzified PSO-SVM controller for motion control of robotic manipulator. *International Journal of Industrial and Systems Engineering*, 24(3), 361-383.
- Khelif, R., Chebel-Morello, B., Malinowski, S., Laajili, E., Fnaiech, F., & Zerhouni, N. (2016). Direct remaining useful life estimation based on support vector regression. *IEEE Transactions on Industrial Electronics*, 64(3), 2276-2285.
- Khelif, R., Malinowski, S., Chebel-Morello, B., & Zerhouni, N. (2014). RUL prediction based on a new similarity-instance based approach. 2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE),
- Kim, N.-H., An, D., & Choi, J.-H. (2017). Prognostics and health management of engineering systems. *Switzerland: Springer International Publishing*.
- Kimotho, J. K., Sondermann-Wölke, C., Meyer, T., & Sextro, W. (2013). Machinery Prognostic Method Based on Multi-Class Support Vector Machines and Hybrid Differential Evolution--Particle Swarm Optimization. *Chemical Engineering Transactions*, 33.
- Kong, D., Chen, Y., Li, N., Duan, C., Lu, L., & Chen, D. (2019). Relevance vector machine for tool wear prediction. *Mechanical Systems and Signal Processing*, 127, 573-594.
- Kothamasu, R., Huang, S. H., & VerDuin, W. H. (2006). System health monitoring and prognostics—a review of current paradigms and practices. *The International Journal of Advanced Manufacturing Technology*, 28(9-10), 1012-1024.
- Kwon, D., Azarian, M. H., & Pecht, M. G. (2008). Detection of solder joint degradation using RF impedance analysis. 2008 58th Electronic Components and Technology Conference,
- Le Son, K., Fouladirad, M., Barros, A., Levrat, E., & Iung, B. (2013). Remaining useful life estimation based on stochastic deterioration models: A comparative study. *Reliability Engineering & System Safety*, 112, 165-175.
- Lebold, M., & Thurston, M. (2001). Open standards for condition-based maintenance and prognostic systems. Maintenance and reliability conference (MARCON),
- Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L., & Siegel, D. (2014). Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. *Mechanical Systems and Signal Processing*, 42(1-2), 314-334.

- Li, D., Wang, W., & Ismail, F. (2013). Enhanced fuzzy-filtered neural networks for material fatigue prognosis. *Applied Soft Computing*, 13(1), 283-291.
- Li, H., Zhao, W., Zhang, Y., & Zio, E. (2020). Remaining useful life prediction using multi-scale deep convolutional neural network. *Applied Soft Computing*, 89, 106113.
- 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.
- Li, X., Duan, F., Mba, D., & Bennett, I. (2017). Multidimensional prognostics for rotating machinery: A review. *Advances in Mechanical Engineering*, 9(2), 1687814016685004.
- Li, Y., & Nilkitsaranont, P. (2008). Gas path prognostic analysis for an industrial gas turbine. *Insight-Non-Destructive Testing and Condition Monitoring*, 50(8), 428-435.
- Liao, L., & Köttig, F. (2014). Review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction. *IEEE Transactions on reliability*, 63(1), 191-207.
- Liu, D., Zhou, J., Pan, D., Peng, Y., & Peng, X. (2015). Lithium-ion battery remaining useful life estimation with an optimized relevance vector machine algorithm with incremental learning. *Measurement*, 63, 143-151.
- Liu, K., Gebrael, N. Z., & Shi, J. (2013). A data-level fusion model for developing composite health indices for degradation modeling and prognostic analysis. *IEEE Transactions on Automation Science and Engineering*, 10(3), 652-664.
- Liu, Q., Dong, M., & Peng, Y. (2012). A novel method for online health prognosis of equipment based on hidden semi-Markov model using sequential Monte Carlo methods. *Mechanical Systems and Signal Processing*, 32, 331-348.
- Loutas, T. H., Roulias, D., & Georgoulas, G. (2013). Remaining useful life estimation in rolling bearings utilizing data-driven probabilistic e-support vectors regression. *IEEE Transactions on reliability*, 62(4), 821-832.
- Lu, C., Chen, J., Hong, R., Feng, Y., & Li, Y. (2016). Degradation trend estimation of slewing bearing based on LSSVM model. *Mechanical Systems and Signal Processing*, 76, 353-366.
- Lu, C., Tao, L., & Fan, H. (2014). An intelligent approach to machine component health prognostics by utilizing only truncated histories. *Mechanical Systems and Signal Processing*, 42(1-2), 300-313.
- Luo, J., Pattipati, K. R., Qiao, L., & Chigusa, S. (2008). Model-based prognostic techniques applied to a suspension system. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 38(5), 1156-1168.
- Malhi, A., Yan, R., & Gao, R. X. (2011). Prognosis of defect propagation based on recurrent neural networks. *IEEE Transactions on Instrumentation and Measurement*, 60(3), 703-711.
- Malhotra, P., Tv, V., Ramakrishnan, A., Anand, G., Vig, L., Agarwal, P., & Shroff, G. (2016). Multi-sensor prognostics using an unsupervised health index based on LSTM encoder-decoder. *arXiv preprint arXiv:1608.06154*.
- Medjaher, K., Tobon-Mejia, D. A., & Zerhouni, N. (2012). Remaining useful life estimation of critical components with application to bearings. *IEEE Transactions on reliability*, 61(2), 292-302.
- Monchy, F., & Vernier, J.-P. (2000). *Maintenance: Méthodes et organisations*. Dunod Paris.
- Mosallam, A., Medjaher, K., & Zerhouni, N. (2016). Data-driven prognostic method based on Bayesian approaches for direct remaining useful life prediction. *Journal of intelligent manufacturing*, 27(5), 1037-1048.
- Motrani, A., & Noureddine, R. (in press). Data-driven prognostic framework for remaining useful life prediction. *International Journal of Industrial and Systems Engineering*. <https://doi.org/10.1504/IJISE.2021.10039700>

- Motrani, A., Nouredine, R., & Nouredine, 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/jsscm.2021.15.01.03>
- Muller, A. (2005). *Contribution à la maintenance prévisionnelle des systèmes de production par la formalisation d'un processus de pronostic* Nancy 1].
- Nagi, I., Yin, D., Yousafzai, A., Tzannetos, D., Mengshoel, O. J., Martin, R., & Kulkarni, C. S. (2019). Exploring Gaussian process regression and unscented Kalman filtering for lithium-ion battery prognostics. AIAA Scitech 2019 Forum,
- Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Chebel-Morello, B., Zerhouni, N., & Varnier, C. (2012). PRONOSTIA: An experimental platform for bearings accelerated degradation tests. IEEE International Conference on Prognostics and Health Management, PHM'12.,
- NFEN13306. (2017). Maintenance—Maintenance Terminology. *BSI Standards Publication*.
- Nieto, P. G., García-Gonzalo, E., Lasheras, F. S., & de Cos Juez, F. J. (2015). Hybrid PSO–SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability. *Reliability Engineering & System Safety*, 138, 219-231.
- Niu, G., & Yang, B.-S. (2010). Intelligent condition monitoring and prognostics system based on data-fusion strategy. *Expert systems with applications*, 37(12), 8831-8840.
- Nouredine, R., Nouredine, F., & Benamar, A. (2013). Condition-based maintenance contribution in machining system. QUALITA2013,
- Orchard, M. E., & Vachtsevanos, G. J. (2007). A particle filtering approach for on-line failure prognosis in a planetary carrier plate. *International Journal of Fuzzy Logic and Intelligent Systems*, 7(4), 221-227.
- 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.
- Pan, Y., Chen, J., & Guo, L. (2009). Robust bearing performance degradation assessment method based on improved wavelet packet–support vector data description. *Mechanical Systems and Signal Processing*, 23(3), 669-681.
- Pan, Y., Er, M. J., Li, X., Yu, H., & Gouriveau, R. (2014). Machine health condition prediction via online dynamic fuzzy neural networks. *Engineering Applications of Artificial Intelligence*, 35, 105-113.
- Pandey, M., & Van Noortwijk, J. (2004). Gamma process model for time-dependent structural reliability analysis. Bridge Maintenance, Safety, Management and Cost, Proceedings of the Second International Conference on Bridge Maintenance, Safety and Management (IABMAS), Kyoto, Japan,
- Patil, M. A., Tagade, P., Hariharan, K. S., Kolake, S. M., Song, T., Yeo, T., & Doo, S. (2015). A novel multistage Support Vector Machine based approach for Li ion battery remaining useful life estimation. *Applied energy*, 159, 285-297.
- PCoE. (2006). *Prognostics Center of Excellence* <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/>
- Pecht, M. (2009). Prognostics and health management of electronics. *Encyclopedia of structural health monitoring*.
- Pecht, M. G. (2010). A prognostics and health management roadmap for information and electronics-rich systems. *IEICE ESS Fundamentals Review*, 3(4), 4\_25-24\_32.
- Peng, Y., Dong, M., & Zuo, M. J. (2010). Current status of machine prognostics in condition-based maintenance: a review. *The International Journal of Advanced Manufacturing Technology*, 50(1-4), 297-313.
- Peng, Y., Wang, H., Wang, J., Liu, D., & Peng, X. (2012). A modified echo state network based remaining useful life estimation approach. 2012 IEEE conference on prognostics and health management,

- Rabiei, E., Droguett, E. L., & Modarres, M. (2016). A prognostics approach based on the evolution of damage precursors using dynamic Bayesian networks. *Advances in Mechanical Engineering*, 8(9), 1687814016666747.
- Ramasso, E. (2014). Investigating computational geometry for failure prognostics in presence of imprecise health indicator: Results and comparisons on c-mapss datasets. PHM Society European Conference,
- Ramasso, E., Rombaut, M., & Zerhouni, N. (2012). Joint prediction of continuous and discrete states in time-series based on belief functions. *IEEE transactions on cybernetics*, 43(1), 37-50.
- Rasmussen, C. E., & Williams, C. (2006). Gaussian processes for machine learning, vol. 1. In: MIT press Cambridge MA.
- Rodríguez, J., Hamzaoui, Y. E., Hernández, J., García, J., Flores, J., & Tejada, A. (2013). The use of artificial neural network (ANN) for modeling the useful life of the failure assessment in blades of steam turbines. *Engineering Failure Analysis*, 35, 562-575.
- Saha, B., & Goebel, K. (2008). Uncertainty management for diagnostics and prognostics of batteries using Bayesian techniques. 2008 IEEE aerospace conference,
- Saha, B., Goebel, K., Poll, S., & Christophersen, J. (2008). Prognostics methods for battery health monitoring using a Bayesian framework. *IEEE Transactions on Instrumentation and Measurement*, 58(2), 291-296.
- Saha, S., Saha, B., Saxena, A., & Goebel, K. (2010). Distributed prognostic health management with Gaussian process regression. 2010 IEEE Aerospace Conference,
- Saidi, L., Ali, J. B., & Fnaiech, F. (2015). Application of higher order spectral features and support vector machines for bearing faults classification. *ISA transactions*, 54, 193-206.
- 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.
- Sankararaman, S. (2015). Significance, interpretation, and quantification of uncertainty in prognostics and remaining useful life prediction. *Mechanical Systems and Signal Processing*, 52, 228-247.
- Saon, S., & Hiyama, T. (2010). Predicting remaining useful life of rotating machinery based artificial neural network. *Computers & Mathematics with Applications*, 60(4), 1078-1087.
- Sateesh Babu, G., Zhao, P., & Li, X.-L. (2016). Deep convolutional neural network based regression approach for estimation of remaining useful life. International conference on database systems for advanced applications,
- Saxena, A., Celaya, J., Balaban, E., Goebel, K., Saha, B., Saha, S., & Schwabacher, M. (2008). Metrics for evaluating performance of prognostic techniques. 2008 international conference on prognostics and health management,
- Saxena, A., Celaya, J. R., Roychoudhury, I., Saha, S., Saha, B., & Goebel, K. (2012). Designing data-driven battery prognostic approaches for variable loading profiles: Some lessons learned. European conference of prognostics and health management society,
- Saxena, A., & Goebel, K. (2008). Turbofan engine degradation simulation data set. *NASA Ames Prognostics Data Repository*, 1551-3203.
- 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.
- Schmolck, A., & Everson, R. (2007). Smooth relevance vector machine: a smoothness prior extension of the RVM. *Machine Learning*, 68(2), 107-135.
- Schwabacher, M. (2005). A survey of data-driven prognostics. In *Infotech@Aerospace* (pp. 7002).

- Seeger, M. (2004). Gaussian processes for machine learning. *International journal of neural systems*, 14(02), 69-106.
- Si, X.-S., Wang, W., Hu, C.-H., Chen, M.-Y., & Zhou, D.-H. (2013). A Wiener-process-based degradation model with a recursive filter algorithm for remaining useful life estimation. *Mechanical Systems and Signal Processing*, 35(1-2), 219-237.
- Si, X.-S., Wang, W., Hu, C.-H., & Zhou, D.-H. (2011). Remaining useful life estimation—a review on the statistical data driven approaches. *European journal of operational research*, 213(1), 1-14.
- Sikorska, J., Hodkiewicz, M., & Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 25(5), 1803-1836.
- Silva, R., Gouriveau, R., Jemei, S., Hissel, D., Boulon, L., Agbossou, K., & Steiner, N. Y. (2014). Proton exchange membrane fuel cell degradation prediction based on adaptive neuro-fuzzy inference systems. *International Journal of Hydrogen Energy*, 39(21), 11128-11144.
- Sloukia, F., El Aroussi, M., Medromi, H., & Wahbi, M. (2013). Bearings prognostic using mixture of gaussians hidden markov model and support vector machine. 2013 ACS International Conference on Computer Systems and Applications (AICCSA),
- Smith, G., Schroeder, J., Navarro, S., & Haldeman, D. (1997). Development of a prognostics and health management capability for the Joint Strike Fighter. 1997 IEEE Autotestcon Proceedings AUTOTESTCON'97. IEEE Systems Readiness Technology Conference. Systems Readiness Supporting Global Needs and Awareness in the 21st Century,
- Soualhi, A., Medjaher, K., & Zerhouni, N. (2014). Bearing health monitoring based on Hilbert–Huang transform, support vector machine, and regression. *IEEE Transactions on Instrumentation and Measurement*, 64(1), 52-62.
- Sun, B., Zeng, S., Kang, R., & Pecht, M. (2010). Benefits analysis of prognostics in systems. 2010 Prognostics and system health management conference,
- Sun, B., Zeng, S., Kang, R., & Pecht, M. G. (2012). Benefits and challenges of system prognostics. *IEEE Transactions on reliability*, 61(2), 323-335.
- Swanson, L. (2001). Linking maintenance strategies to performance. *International journal of production economics*, 70(3), 237-244.
- Takata, S., Kirnura, F., van Houten, F. J., Westkamper, E., Shpitalni, M., Ceglarek, D., & Lee, J. (2004). Maintenance: changing role in life cycle management. *CIRP annals*, 53(2), 643-655.
- Tipping, M. E. (2001). Sparse Bayesian learning and the relevance vector machine. *Journal of machine learning research*, 1(Jun), 211-244.
- Tsui, K. L., Chen, N., Zhou, Q., Hai, Y., & Wang, W. (2015). Prognostics and health management: A review on data driven approaches. *Mathematical Problems in Engineering*, 2015.
- Tzikas, D. G., Wei, L., Likas, A., Yang, Y., & Galatsanos, N. P. (2006). A tutorial on relevance vector machines for regression and classification with applications. *EURASIP News Letter*, 17(2), 4.
- Vachtsevanos, G. J., & Vachtsevanos, G. J. (2006). *Intelligent fault diagnosis and prognosis for engineering systems* (Vol. 456). Wiley Online Library.
- Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE transactions on neural networks*, 10(5), 988-999.
- Voisin, A., Medina-Oliva, G., Monnin, M., Leger, J.-B., & Iung, B. (2013). Fleet-wide diagnostic and prognostic assessment. Annual Conference of the Prognostics and Health Management Society 2013,
- Wang, B., Lei, Y., Li, N., & Yan, T. (2019). Deep separable convolutional network for remaining useful life prediction of machinery. *Mechanical Systems and Signal Processing*, 134, 106330.

- Wang, D., Miao, Q., & Pecht, M. (2013). Prognostics of lithium-ion batteries based on relevance vectors and a conditional three-parameter capacity degradation model. *Journal of Power Sources*, 239, 253-264.
- Wang, H., Lee, J., Ueda, T., Adjallah, K. H., & Ghaffari, M. (2007). Engine health assessment and prediction using the group method of data handling and the method of match matrix: Autoregressive moving average. *Turbo Expo: Power for Land, Sea, and Air*,
- Wang, P., & Vachtsevanos, G. (2001). Fault prognostics using dynamic wavelet neural networks. *AI EDAM*, 15(4), 349-365.
- Wang, P., Youn, B. D., & Hu, C. (2012). A generic probabilistic framework for structural health prognostics and uncertainty management. *Mechanical Systems and Signal Processing*, 28, 622-637.
- Wang, T., Yu, J., Siegel, D., & Lee, J. (2008). A similarity-based prognostics approach for remaining useful life estimation of engineered systems. 2008 international conference on prognostics and health management,
- Widodo, A., & Yang, B.-S. (2011). Application of relevance vector machine and survival probability to machine degradation assessment. *Expert systems with applications*, 38(3), 2592-2599.
- Wu, W., Hu, J., & Zhang, J. (2007). Prognostics of machine health condition using an improved ARIMA-based prediction method. 2007 2nd IEEE Conference on Industrial Electronics and Applications,
- Wu, Y., Yuan, M., Dong, S., Lin, L., & Liu, Y. (2018). Remaining useful life estimation of engineered systems using vanilla LSTM neural networks. *Neurocomputing*, 275, 167-179.
- Xi, Z., Jing, R., Wang, P., & Hu, C. (2014). A copula-based sampling method for data-driven prognostics. *Reliability Engineering & System Safety*, 132, 72-82.
- Xing, Y., Ma, E. W., Tsui, K.-L., & Pecht, M. (2013). An ensemble model for predicting the remaining useful performance of lithium-ion batteries. *Microelectronics reliability*, 53(6), 811-820.
- Xue, Z., Zhang, Y., Cheng, C., & Ma, G. (2020). Remaining useful life prediction of lithium-ion batteries with adaptive unscented kalman filter and optimized support vector regression. *Neurocomputing*, 376, 95-102.
- Yan, J., Liu, Y., Han, S., & Qiu, M. (2013). Wind power grouping forecasts and its uncertainty analysis using optimized relevance vector machine. *Renewable and sustainable energy reviews*, 27, 613-621.
- Yang, F., Habibullah, M. S., Zhang, T., Xu, Z., Lim, P., & Nadarajan, S. (2016). Health index-based prognostics for remaining useful life predictions in electrical machines. *IEEE Transactions on Industrial Electronics*, 63(4), 2633-2644.
- Yin, S., Ding, S. X., & Zhou, D. (2016). Diagnosis and prognosis for complicated industrial systems—Part I. *IEEE Transactions on Industrial Electronics*, 63(4), 2501-2505.
- Yuan, M., Wu, Y., & Lin, L. (2016). Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network. 2016 IEEE international conference on aircraft utility systems (AUS),
- Zemouri, R., & Gouriveau, R. (2010). Towards accurate and reproducible predictions for prognostic: an approach combining a RRBF network and an autoregressive model. *IFAC Proceedings Volumes*, 43(3), 140-145.
- Zemouri, R., Racoceanu, D., & Zerhouni, N. (2003). Recurrent radial basis function network for time-series prediction. *Engineering Applications of Artificial Intelligence*, 16(5-6), 453-463.
- Zhang, A., Wang, H., Li, S., Cui, Y., Liu, Z., Yang, G., & Hu, J. (2018). Transfer learning with deep recurrent neural networks for remaining useful life estimation. *Applied Sciences*, 8(12), 2416.

- 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.
- Zhang, Q., Liu, F., Wan, X., & Xu, G. (2015). An adaptive support vector regression machine for the state prognosis of mechanical systems. *Shock and Vibration*, 2015.
- Zheng, S., Ristovski, K., Farahat, A., & Gupta, C. (2017). Long short-term memory network for remaining useful life estimation. 2017 IEEE international conference on prognostics and health management (ICPHM),
- Zhu, J., Chen, N., & Peng, W. (2018). Estimation of bearing remaining useful life based on multiscale convolutional neural network. *IEEE Transactions on Industrial Electronics*, 66(4), 3208-3216.
- Zio, E., & Di Maio, F. (2010). A data-driven fuzzy approach for predicting the remaining useful life in dynamic failure scenarios of a nuclear system. *Reliability Engineering & System Safety*, 95(1), 49-57.