

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Batna 2 – Mostefa Ben Boulaïd
Faculté de Technologie
Département de Génie Industriel



Thèse

Préparée au sein du laboratoire d'automatique et productique

Présentée pour l'obtention du diplôme de :

Doctorat en Sciences en Génie Industriel
Option : Génie Industriel

Sous le Thème :

**Développement de méthodes hybrides pour le
pronostic des systèmes de production**

Présentée par

MOHAMMED Bouzenita

Devant le jury composé de :

M. Mohamed Djamel MOUSS	Prof. Université Batna 2	Président
M. Leila Hayet MOUSS	Prof. Université Batna 2	Rapporteur
M. Hassen BOUZGOU	Prof. Université Batna 2	Examineur
M. Okba KAZAR	Prof. Université de Biskra	Examineur
M. Khaled REZEG	Prof. Université de Biskra	Examineur
M. Brahim LEJDEL	Prof. Université El Oued	Examineur
M. Farid MELGANI	Prof. Université de Trento, Italie	Invité

Octobre 2022



Remerciements

Louange à Allah, que la paix et la bénédiction soient sur Prophète Mohammed, ainsi que sur sa famille et ses compagnons.

En respectant la consigne du prophète (Paix et bénédiction sur lui) qui disait : "CELUI QUI NE REMERCIE PAS LES GENS N'AURA PAS REMERCIÉ ALLAH", je voudrais adresser mes plus vifs remerciements à certaines personnes. Franchement, la présente thèse n'aurait pas vu le jour sans leur support et orientation.

Ce travail de thèse a été réalisé au sein du laboratoire d'Automatique et Productique à l'Université de Mostepha Benboulaïd, Batna 2.

Tous d'abord, j'exprime mes plus profonds remerciements à Madame le Professeur **LEILA HAYET MOUSS** directrice de cette thèse pour sa disponibilité, son support et ses conseils pertinentes.

Je tiens à remercier Monsieur le Professeur **MOHAMED DJAMEL MOUSS**, chef de département de génie industriel, d'avoir accepté la lourde responsabilité de présider ce jury.

Je tiens également à remercier Monsieur **HASSEN BOUZGOU** Professeur à l'Université de Batna 2 d'avoir accepté d'être parmi nous.

Je remercie vivement Monsieur **OKBA KAZAR** Professeur à l'Université de Biskra pour l'honneur qu'il m'a fait de siéger parmi les membres du jury.

Je souhaiterais exprimer ma gratitude à Monsieur **KHALED REZEG** Professeur à l'Université de Biskra pour avoir participé à mon jury de thèse.

Je tiens également à remercier Monsieur **FARID MELGANI** Professeur à l'Université de Trento –Italie, pour m'avoir accueilli au sein du Laboratoire LSPR de Trento, pour ses orientations précises qui m'ont beaucoup aidé pour me faire avancer dans cette thèse, et ainsi que d'avoir accepté notre invitation.

Je suis particulièrement reconnaissant à mon collègue et frère Docteur **TOUFIK BENTRCIA** non seulement pour ses orientations, ses suggestions et ses remarques judicieuses depuis mon inscription au Magister à nos jours, mais également pour sa relecture très rigoureuse de ma thèse malgré ses nombreuses occupations.

Sans doute, un remerciement spécial à ma grande famille, ma petite famille et mes amis pour leurs soutient et encouragement.

Dédicaces

A ma très chère mère pour sa patience et sa générosité et qui n'a cessé de prier pour moi.

A mon très cher père pour son encouragement et son soutien moral.

A ma femme pour sa patience et qui a su me remonter le moral dans les moments les plus difficiles.

A mes enfants, qui ont donné le gout à ma vie : Mouaddh, Douaa et Baraa Ibrahim.

A mes chers frères et à ma sœur, pour leur appui et leur encouragement.

A toute ma famille.

A tous mes amis.

A tous ceux que j'aime et qui m'aiment.

Table des matières

Table des matières	v
Liste des figures	ix
Liste des tableaux	xi
Liste des algorithmes	xiii
Liste des abréviations	xv
Introduction générale	1
1 Pronostic industriel : Concepts, techniques et applications	5
1.1 Introduction	6
1.2 Cadre de pronostic	6
1.2.1 Définition de pronostic	7
1.2.2 Quelques activités relatives	7
1.2.2.1 Surveillance	7
1.2.2.2 Indice d'état (Health index)	7
1.2.2.3 Durée de vie utile restante (Remaining useful life)	8
1.3 Différentes approches du pronostic	8
1.3.1 Approches basées sur un modèle physique	8
1.3.1.1 Classification des approches basées sur un modèle physique	9
1.3.1.2 Avantages et inconvénients	10
1.3.1.3 Techniques	11
1.3.2 Approches guidées par les données	13
1.3.2.1 Classification des approches guidées par les données	13
1.3.2.2 Avantages et inconvénients	14
1.3.2.3 Techniques	15
1.3.3 Approches basées sur l'expérience ou la connaissance	17
1.3.3.1 Classification des approches basées sur l'expérience	18
1.3.3.2 Avantages et inconvénients	19
1.3.3.3 Techniques	20
1.3.4 Approches hybrides	21
1.3.4.1 Configurations des approches hybrides	21
1.3.4.2 Stratégies de combinaison	22
1.3.4.3 Avantages et inconvénients	25
1.3.4.4 Techniques	26
1.4 Applications de pronostic	28
1.4.1 Domaines d'application	28
1.4.2 Applications focalisées sur des composants	28
1.5 Jeux de données	29
1.6 Conclusion	31

Références	32
2 Nouvelles approches hybrides de pronostic à base du GPR et IOWA	45
2.1 Introduction	46
2.2 Etat de l'art	47
2.3 Description des techniques adoptées	48
2.3.1 Régression par processus gaussien	48
2.3.2 Opérateurs de moyenne pondérée ordonnée induits (IOWA)	50
2.4 Description du cadre de fusion proposé	51
2.4.1 Conversion des données originales en valeurs différentielles	52
2.4.2 Génération des modèles de régression par processus gaussien	53
2.4.3 Fusion avec les opérateurs IOWA	54
2.4.3.1 Détermination des poids	54
2.4.3.2 Agrégation / Sélection des différences prédites des données de test	55
2.4.4 Conversion des données de différences prédites en données d'origine	55
2.5 Données expérimentales et résultats	56
2.5.1 Conversion des données originales en valeurs de différence	60
2.5.2 Génération des modèles de régression par processus gaussien	60
2.5.3 Fusion avec les opérateurs IOWA	61
2.6 Conclusion	73
Références	75
3 Nouveaux cadres hybrides de pronostic à base des fonctions de pondération explicites	79
3.1 Introduction	80
3.2 Etat de l'art	81
3.3 Contexte théorique	83
3.3.1 Estimation basée sur un processus gaussien	83
3.3.2 Aperçu sur la méthode IOWA	85
3.4 Schéma de pondération proposé	86
3.4.1 Prétraitement des données originales	87
3.4.2 Élaboration des modèles GPR	88
3.4.2.1 Fusion avec les opérateurs IOWA	88
3.4.2.2 Détermination des poids	88
3.4.2.3 Procédure d'agrégation	90
3.4.3 Conversion des résultats au format primaire	92
3.5 Expériences et résultats numériques	92
3.5.1 Transformation des données brutes en valeurs de gradient	94
3.5.2 Élaboration des modèles GPR	95
3.5.3 Résultats des techniques d'agrégation proposées	96
3.5.4 Discussion	104
3.6 Conclusion	105
Références	106
4 Développement d'un algorithme génétique hybride pour le pronostic industriel	111
4.1 Introduction	112
4.2 Etat de l'art	113
4.3 Vue d'ensemble des techniques adoptées	115
4.3.1 Algorithmes génétiques	115
4.3.1.1 Éléments de l'AG	115

4.3.1.2	Variantes de l'AG	117
4.3.2	Régression par processus gaussien	119
4.3.3	ANFIS : Système d'inférence flou basé sur un réseau adaptatif (Adaptive- Network-Based Fuzzy Inference System)	120
4.3.3.1	Architecture de l'ANFIS	120
4.3.3.2	Algorithme d'apprentissage ANFIS	122
4.4	Cadre de l'approche hybride proposée	122
4.4.1	Initialisation des paramètres et préparation des données	122
4.4.2	Optimisation de l'AG	124
4.4.3	Phase de prédiction	126
4.5	Données expérimentales et résultats	126
4.5.1	Initialisation des paramètres et préparation des données	128
4.5.2	Optimisation de l'AG	130
4.5.3	Phase de prédiction	130
4.6	Conclusion	135
	Références	136
	Conclusion générale et perspectives	139
	Résumé	

Liste des figures

1.1	Illustration de différents concepts de pronostic	8
1.2	Classification des approches du pronostic	9
1.3	Organigramme d'approche basée sur un modèle physique	10
1.4	Cadre de l'approche guidée par les données	13
1.5	Cadre d'approche basée sur les connaissances	18
1.6	Configurations des méthodes hybrides	22
1.7	Combinaisons hybrides possibles des approches de pronostic	23
2.1	Illustration des étapes principales de l'approche proposée	52
2.2	Evolution de critère SOH des batteries en fonction de nombre de cycle	59
2.3	Illustration de mesure SOH de batterie No. 5 avec les deux régions d'apprentissage et de test	59
2.4	Transformation des données d'apprentissage en valeurs de gradient	61
2.5	Prédiction du critère SOH à base de la fonction de covariance SE	63
2.6	Prédiction du critère SOH basée sur une procédure de fusion simple sans l'étape de transformation en différences	63
2.7	Prédiction du critère SOH basée sur la fusion des fonctions de covariance SE (trente initialisations pour les hyperparamètres)	64
2.8	Prédiction du critère SOH basée sur la fusion des fonctions de covariance périodiques conjointement avec les fonctions de covariance additionnelles proposées pour chaque scénario (quinze initialisations des hyper-paramètres pour chaque modèle)	65
2.9	Prédiction du critère SOH basée sur la fusion de fonctions de covariance composites (trente initialisations pour les hyper-paramètres)	66
2.10	Comparaison des estimateurs GPR et du résultat de fusion correspondant	67
2.11	Prédiction du critère SOH basée sur la fusion des fonctions de covariance périodiques conjointement avec les fonctions de covariance additionnelles proposées pour les scénarios 3 et 5 (batteries 6,7 et 18)	69
2.12	Variation des valeurs RMSE du test en fonction du nombre de répétitions de l'expérience	71
2.13	Présentation des diagrammes en boîte associés aux valeurs RMSE du test pour les deux techniques	72
2.14	Présentation des diagrammes en boîte associés aux valeurs RMSE du test pour chaque sous-ensemble pour les deux techniques	74
3.1	Visualisation des étapes principales du cadre de fusion proposé	87
3.2	Vecteurs de pondération des trois approches proposées	90
3.3	Organigramme de l'approche générique proposée	91
3.4	Vue schématique des différents composants d'une batterie lithium-ion	92
3.5	Progression de la valeur SOH des batteries en fonction du nombre de cycles	93
3.6	Progression de la valeur SOH de la batterie n° 5 avec visualisation des zones d'apprentissage et de test	94
3.7	Transformation des données d'apprentissage en valeurs de gradient	95

3.8	Estimation de la mesure SOH basée sur des fonctions de pondération exponentielle, logarithmique et inverse en utilisant les premiers 25% des éléments (C1 : Configuration 1, C2 : Configuration 2)	97
3.9	Estimation de la mesure SOH basée sur la pondération exponentielle, logarithmique et inverse en utilisant les premiers 25% des éléments en plus des résultats standards IOWA (C1 : Configuration 1, C2 : Configuration 2)	98
3.10	Estimation de la mesure SOH basée sur la pondération exponentielle, logarithmique et inverse en utilisant tous les éléments (C1 : Configuration 1, C2 : Configuration 2)	98
3.11	Estimation de la mesure SOH basée sur la fonction de pondération exponentielle pour la première configuration avec un niveau de confiance de 95%	100
3.12	Estimation de la mesure SOH basée sur des fonctions de pondération exponentielle, logarithmique et inverse en utilisant l'erreur d'apprentissage (C1 : Configuration 1, C2 : Configuration 2)	101
3.13	Temps CPU en fonction du nombre de GPR agrégés basé sur le IOWA standard	103
3.14	Temps CPU en fonction du nombre de GPR agrégés selon les trois approches proposées	104
4.1	Illustration de différents concepts de pronostic	112
4.2	Opérateurs de croisement largement utilisés	116
4.3	Illustration de quelques procédures de mutation	117
4.4	Liste récapitulative de quelques opérateurs d'algorithmes génétiques	118
4.5	Architecture ANFIS (en bas) et modèle flou équivalent de Sugeno de premier ordre à deux entrées avec deux règles (en haut)	121
4.6	Etapes principales de l'approche proposée	123
4.7	Architecture proposée pour le codage du chromosome (solution)	124
4.8	Architecture de la population proposée	124
4.9	Evolution du critère SOH des batteries en fonction du nombre de cycles	127
4.10	Illustration de la mesure SOH de la batterie n° 5, y compris les régions d'apprentissage, de validation et de test	128
4.11	Exemple d'un échantillon de chromosome	130
4.12	Meilleure solution obtenue pour la batterie 5	131
4.13	Valeur de la fonction objectif en fonction du nombre d'itérations, appliquée à la batterie 5	131
4.14	Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 5	132
4.15	Comparaison des prédicteurs sélectionnés et du résultat de la fusion correspondante	132
4.16	Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 6	133
4.17	Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 7	133
4.18	Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 18	134

Liste des tableaux

1.1	Quelques applications des approches basées sur le modèle physique	12
1.2	Quelques applications des méthodes guidées par les données	17
1.3	Quelques applications de modèles basés sur la connaissance	21
1.4	Quelques applications courantes des modèles hybrides	27
2.1	Fonctions de covariance utilisées pour générer les ensembles de différentes expériences	62
2.2	Résultats des prédictions pour les dix scénarios appliqués à la batterie n°5 . .	68
2.3	Résultats des prédictions pour les dix scénarios appliqués à la batterie n°6 . .	68
2.4	Résultats des prédictions pour les dix scénarios appliqués à la batterie n°7 . .	68
2.5	Résultats des prédictions pour les dix scénarios appliqués à la batterie n°18 .	68
2.6	Consommation de temps en secondes pour les dix scénarios appliqués à la batterie no.5	70
2.7	Comparaisons des approches proposées et de certains travaux de référence pour les batteries 5, 6, 7 et 18	75
3.1	Résumé des travaux connexes par rapport aux caractéristiques de pronostic souhaitées	82
3.2	Fonctions de covariance adoptées pendant la phase de génération du GPR . .	95
3.3	Moyenne des RMSEs d'entraînement des premiers 25%, 50% et 75% des éléments	97
3.4	Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 5	99
3.5	Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 6	100
3.6	Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 7	100
3.7	Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 18	101
3.8	Résumé des erreurs obtenues pour les trois approches proposées en fonction de l'erreur d'apprentissage, appliquées aux batteries 5, 6, 7 et 18	102
3.9	Évaluation du temps en secondes pour les deux configurations dans le cas de la batterie n° 5	102
3.10	Résumé des erreurs obtenues pour les trois approches proposées en fonction de l'erreur d'apprentissage, appliquées aux batteries 5, 6, 7 et 18	105
4.1	Deux passages de la procédure d'apprentissage hybride d'ANFIS	122
4.2	: Notations et valeurs des paramètres et fonctions adoptés	129
4.3	Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°5	134
4.4	Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°6	134

4.5	Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°7	135
4.6	Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°18	135
4.7	Comparaison de l'approche proposée et de certains travaux de référence pour les batteries 5, 6, 7 et 18	135

Liste des algorithmes

2.1	Mean fusion	56
2.2	IOWA fusion	57
2.3	Min variance selection	58
4.1	Algorithme génétique classique	117
4.2	Fonction objectif proposée	125
4.3	Prédiction	126

Liste des abréviations

AG	Algorithme Génétique
ANFIS	Adaptive Network-Based Fuzzy Inference System
AR	Auto Regressive model
BM	Bayesian method
BN	Bayesian networks
CALCE	Center for Advanced Life Cycle Engineering
CBM	Conditional Based Maintenance
CNN	Convolutional Neural Network
EKf	Extended Kalman filter
EoL	End of life
GP	Gaussian Process
GPR	Gaussian Process Regression
HMM	Hidden Markov Model
HUMS	Health and Usage Monitoring System
HI	Health Index
IA	Intelligence Artificielle
IMS	Intelligent Maintenance Systems
IOWA	Induced Ordered Weighted Averaging
IVHM	Integrated Vehicle Health Management
KF	Kalman filter
MAPE	Mean Absolute Percentage Error
MTTF	Mean Time to Failure
OWA	Ordered Weighted Averaging
PCoE	Prognostics Center of Excellence
PDF	Probability Density Function
PE	Paris-Erdogan model
PHI	Physic Health Indicator
PHM	Prognostics and Health Managment
PoF	Physics of Failure
RBM	Restricted Boltzmann machine
RMSE	Root Mean Squared Error
RNA	Réseau de Neurones Artificiels
RNN	Recurrent Neural Network
RVM	Relevance Vector Machine
RUL	Remaining Useful Life
SE	Systèmes Experts
SOH	State of Health
SVM	Support Vector Machine
VHI	Virtual Health Indicator

Introduction générale

Contexte et motivation

L'un des éléments clés des systèmes de production est la politique de maintenance, qui a évolué au fil des années, passant d'une simple stratégie basée sur la réparation des défaillances après leur apparition, connue sous le nom de maintenance corrective, à une vision plus élaborée qui est la maintenance préventive. Dans cette stratégie, l'intervention est effectuée en respectant certains intervalles déterminés sur la base de facteurs de fiabilité statistiques connexes. Par la suite, la maintenance conditionnelle (CBM) a été introduite, où la tâche de maintenance est effectuée en réponse à une alarme déclenchée si certains seuils de fiabilité définis sont dépassés. Actuellement, le pronostic et la gestion de l'état des systèmes (PHM) est la stratégie de maintenance la plus avancée, mais la politique CBM est la vision de maintenance la plus adoptée en raison du coût et de la complexité de l'installation PHM [1]. L'adoption d'une telle maintenance prédictive présente plusieurs avantages, notamment la réduction des coûts de maintenance et la diminution de la durée en panne, ce qui implique une augmentation du taux de production [2]. La popularité de l'approche PHM a augmenté avec l'arrivée de l'industrie 4.0. Dans cette nouvelle ère d'organisation, une grande quantité de données est collectée et manipulée à l'aide de capteurs dédiés installés sur les machines et les emplacements critiques. De plus, la liaison des clusters de calcul à haute performance (HPC) aux installations industrielles, la connectivité à l'internet des objets (IoT) et les technologies 'big data' sont absolument nécessaires pour traiter efficacement des structures de données énormes et sophistiquées. En raison de ces contraintes, un intérêt accru a été porté à la stratégie PHM, ce qui a conduit à l'augmentation considérable de sa popularité [1].

Le rôle principal de l'approche d'ingénierie PHM est l'évaluation de l'état réel du système. En gros, on y parvient en prédisant non seulement le comportement futur mais aussi la durée de vie utile restante à l'aide des informations disponibles recueillies au fil du temps [3]. Le pronostic du comportement futur d'un système peut être réalisé par trois approches principales : les méthodes basées sur la physique, qui utilisent principalement des modèles mathématique et physique du fonctionnement du système. Les méthodes fondées sur les données, qui reposent sur l'étude des données numériques fournies à l'aide de techniques avancées d'apprentissage automatique, et les méthodes fondées sur les connaissances, qui reposent sur les connaissances d'experts. Ces dernières années, une nouvelle classe de méthodes de pronostic a été introduite pour exploiter les avantages et contourner les défauts des techniques précédentes en considérant des cadres intégrés utilisant des stratégies de fusion vigilantes. Il convient de mentionner que cette classe peut être considérée comme un domaine en pleine expansion en raison de l'intérêt croissant suscité par les communautés industrielles et universitaires. Les outils mis en œuvre dans cette classe sont connus sous le nom de méthodes hybrides et ils constitueront l'objectif principal de ce travail. Dans ce contexte, notre thèse est consacrée au développement de nouvelles méthodes hybrides remédiant de nombreuses lacunes et couvrant certains aspects qui, à notre connaissance, n'ont pas encore été étudiés dans la littérature existante.

Contributions

Les principales contributions de cette thèse sont :

- Réalisation d'une synthèse érudite de la littérature disponible pour extraire et présenter les techniques récentes de pronostic et notamment la vision hybride où les stratégies de combinaison sont détaillées ;
- Proposition d'approches hybrides robuste en développant différentes stratégies de fusion utilisant l'apprentissage automatique comme IOWA, les fonctions analytiques explicites (proposées) et les méthodes métaheuristiques (AG), où un jeu de données réelles est étudié pour la mise en œuvre pratique des approches proposées ;
- Introduction de la méthode IOWA en tant que technique de fusion qui, à notre connaissance, n'a pas été exploitée pour ce but auparavant, où nous avons introduit certaines spécifications concernant la composante cruciale, à savoir l'ordre d'induction [4] ;
- Proposition d'une phase préliminaire indispensable pour avoir une bonne performance, où les données d'apprentissage initiales sont transformées en valeurs de gradient. Cette transformation représente une contribution originale dans le domaine du pronostic ;
- Introduction du temps d'exécution en tant que facteur de performance pour l'évaluation précise des approches proposées. Ce critère n'a pas été pris en considération dans plusieurs travaux connexes ;
- Réalisation d'une comparaison avec les travaux existants dans la littérature pour valider les méthodes de pronostic hybrides proposées, où nous avons révélé la performance et la capacité satisfaisantes des méthodes développées.

Organisation

Le présent travail est organisé en quatre chapitres dont le premier est réservé à l'état de l'art relatif aux méthodes de pronostic. Les trois autres chapitres sont associés aux stratégies hybrides proposées et développées, où une revue de littérature spécifique est présentée pour chaque chapitre. La structure détaillée de la thèse est illustrée ci-dessous :

Dans le chapitre 1, notre objectif est de mettre en pratique notre thème de recherche en fournissant une vue globale du domaine du pronostic et de la gestion de l'état des systèmes industriels. Tout d'abord, nous présentons les principaux concepts du domaine du pronostic et nous détaillons de manière claire les différentes approches de pronostic disponibles, y compris leur classification, leurs principaux avantages et inconvénients et les techniques existantes, ainsi que quelques références importantes associées. Nous décrivons ensuite différentes stratégies de combinaison employées pour développer des approches hybrides. Enfin, nous fournissons quelques applications de pronostic et offrons au lecteur quelques jeux de données largement utilisés pour le pronostic.

Le chapitre 2 est consacré à la présentation des approches de fusion et de sélection proposées pour l'estimation de la durée de vie utile restante basé sur les opérateurs IOWA. Nous fournissons diverses composantes exploitées lors du développement des nouvelles approches. Dans ce chapitre, nous proposons une transformation des données utilisées en valeurs de gradient, où une amélioration remarquable est obtenue. Des résultats expérimentaux utilisant un jeu de données de batteries sont présentés et une comparaison en termes de critères de performance avec certaines études disponibles est exposée.

La contribution du chapitre 3 porte sur la proposition de trois fonctions de pondération analytiques (pondération exponentielle, pondération logarithmique et pondération inverse) à des fins de fusion. Nous discutons en détail la procédure de détermination des poids explicites et du processus d'agrégation. De plus, nous introduisons le temps de fonctionnement comme nouvelle mesure de comparaison des performances afin d'évaluer les approches développées avec les modèles de fusion proposés dans le chapitre précédent en utilisant le même benchmark. En outre, le facteur d'incertitude est pris en compte dans les approches hybrides établies. Nous fournissons également une comparaison des méthodes développées avec d'autres travaux extraits de la littérature.

Un algorithme génétique hybride de pronostic est développé dans le chapitre 4 pour prédire la durée de vie utile restante. L'AG est étudiée pour attribuer des poids appropriés à un ensemble de régresseurs compétitifs. Nous avons proposé trois étapes principales : initialisation des paramètres et préparation des données, processus d'optimisation de l'AG et phases de prédiction. Ces phases sont décrites pour clarifier le codage des chromosomes et l'exécution des tâches de pronostic. Les mêmes jeux de données utilisés dans les deux chapitres précédents sont adoptés comme référence pour valider l'algorithme génétique hybride de pronostic proposé, où une comparaison avec certains articles traitant la même application est établie.

Nous terminons ce travail par une conclusion et quelques perspectives.

Références

1. BAUR, M., ALBERTELLI, P. & MONNO, M. A review of prognostics and health management of machine tools. *The International Journal of Advanced Manufacturing Technology* **107**. Number : 5, 2843-2863. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-020-05202-3> (1^{er} mars 2020).
2. MONTERO-JIMENEZ, J. J., SCHWARTZ, S., VINGERHOEDS, R., GRABOT, B. & SALAÜN, M. Towards multi-model approaches to predictive maintenance : A systematic literature survey on diagnostics and prognostics. *Journal of Manufacturing Systems* **56**, 539-557. ISSN : 0278-6125. <http://www.sciencedirect.com/science/article/pii/S0278612520301187> (1^{er} juill. 2020).
3. KIM, N.-H., AN, D. & CHOI, J.-H. in *Prognostics and Health Management of Engineering Systems* 1-24 (Springer, Cham, 2017). ISBN : 978-3-319-44740-7 978-3-319-44742-1.
4. BOUZENITA, M., MOUSS, L.-H., MELGANI, F. & BENTRCIA, T. New fusion and selection approaches for estimating the remaining useful life using Gaussian process regression and induced ordered weighted averaging operators. *Quality and Reliability Engineering International* **36**, 2146-2169. ISSN : 1099-1638. <https://onlinelibrary.wiley.com/doi/abs/10.1002/qre.2688> (2020).

Chapitre 1

Pronostic industriel : Concepts, techniques et applications

Résumé : Le présent chapitre est consacré à la présentation d'une vue globale des approches de pronostic industriel et de la gestion de l'état des systèmes de production. Premièrement, une présentation des principaux concepts de pronostic industriel est introduite. Ensuite, nous détaillons d'une façon claire les approches de pronostic adoptées dans la littérature et notamment les approches hybrides ainsi que leur classification, les principaux avantages et inconvénients et les techniques associées. Nous exposons d'une manière rigoureuse les techniques et stratégies possibles pour le développement des approches hybrides de pronostic industriel. Des tableaux clés montrant quelques références importantes pour l'application des approches de pronostic présentées, sont fournis. Enfin, nous décrivons les champs d'application de ces techniques en indiquant les domaines généraux les plus ciblés ainsi que quelques composants critiques nécessitant une surveillance efficace. Une liste de quelques jeux de données largement utilisés dans le domaine de pronostic industrielle est révélée au lecteurs intéressés par le développement des approches de pronostic efficaces.

1.1 Introduction

Le Pronostic et Management de la Santé des systèmes industriels (en anglais : Prognostics and Health Management PHM), est un nouveau concept introduit non seulement pour surveiller l'état des systèmes industriels en respectant leurs conditions de fonctionnement mais aussi pour fournir des informations précises sur l'état futur. Le terme PHM a été introduit initialement dans le domaine médical. Il était focalisé sur le prétraitement des patients après la prédiction de toute maladie probable. Le concept a été ensuite adopté en mécanique dans le but d'estimer toute dégradation ou défaillance possible afin d'effectuer la maintenance préconisée [1].

L'émergence du PHM date aux années 1980 par l'Autorité de l'aviation civile du Royaume-Uni pour minimiser les accidents d'hélicoptère. Un système de surveillance des hélicoptères « Health and Usage Monitoring System » (HUMS) a été développé en 1990 [2]. L'introduction du concept PHM dans les systèmes aéronautiques permet d'alerter les opérateurs de toute situation critique en intégrant des alarmes et des analyses de tendances [3]. Dans la même année, la NASA a introduit un système de gestion intégrée de l'état des véhicules « Integrated Vehicle Health Management (IVHM) » pour surveiller et pronostiquer différents systèmes spatiaux [2]. Le terme PHM a ensuite connu un essor dans différents domaines et a attiré l'attention de nombreux centres et instituts tels que, Center for Advanced Life Cycle Engineering (CALCE), Intelligent Maintenance Systems (IMS) Center, FEMTO-ST Institute, PHM Society et NASA Prognostics Center of Excellence (PCoE). Le concept PHM suscite de plus en plus l'intérêt des ingénieurs industriels et des chercheurs universitaires où nombreux travaux ont été publiés ces dernières années. Plus de 850 articles sur le pronostic des machines ont été publiés entre 2012 et 2016, alors que seulement 572 travaux ont été publiés durant la période de 1997 à 2011 [4]. L'ingénierie de fiabilité, la physique des défaillances, les technologies de détection, les méthodes statistiques et les méthodes d'apprentissage automatique sont les techniques les plus populaires introduites pour gérer la gestion de l'état des équipements en temps réel en utilisant les données historiques fournies [2].

Dans ce chapitre, nous présentons les principaux concepts du pronostic dans la section 1.2 et nous détaillons d'une manière rigoureuse les différentes approches adoptées dans le domaine du PHM dans la section 1.3. Les applications de ces méthodes ainsi que les différents jeux de données exploités dans la littérature sont présentées respectivement dans les sections 1.4 et 1.5. Nous terminons ce chapitre par quelques remarques et conclusions.

1.2 Cadre de pronostic

Le pronostic est considéré comme une tâche principale qui vise à prédire l'état futur des systèmes industriels. Dans cette section, nous présentons les principaux concepts du pronostic.

1.2.1 Définition de pronostic

Il n'existe pas une définition universelle du terme pronostic, une liste de quelques définitions proposées est présentée ci-dessous [5, 6] :

- Le pronostic est un processus permettant de prédire la dégradation future et la durée de vie utile restante (RUL) du système en utilisant les données de dégradation disponibles.
- Sous ISO 13381-1, le pronostic est défini comme une estimation du temps de défaillance et du risque pour un ou plusieurs modes de défaillance existants et futurs.
- Le pronostic consiste à prédire les défaillances/dégradations futures et estimer le RUL des systèmes en service en utilisant les jeux de données des défaillances.
- Le pronostic est le processus de prédiction de la fiabilité future d'un produit en évaluant l'étendue de la dérivation ou de la dégradation du produit par rapport à ses conditions de fonctionnement normales attendues. Il s'agit de la prédiction de leur état futur en se basant sur les conditions d'état actuelles et passé.

La première définition est sélectionnée comme étant une définition clé pour notre tâche de pronostic.

1.2.2 Quelques activités relatives

Dans cette sous-section, nous introduisons quelques activités liées à la tâche de pronostic.

1.2.2.1 Surveillance

La surveillance fait référence à la vérification des performances de la machine via la comparaison du comportement actuel avec l'état normal souhaité. La différence entre les deux états est dit résidu où une alarme est déclenchée en cas d'une différence significative. Lorsqu'un comportement anormal est détecté, le module de diagnostic ou de pronostic est activé pour prédire quel mode de défaillance est ou sera apparu. La différence entre les machines et la variation des conditions de fonctionnement sont sources de fausse alarme, ce qui est l'un des principaux défis relatifs à la procédure de surveillance [7].

1.2.2.2 Indice d'état (Health index)

L'indice d'état (HI) reflète le comportement de dégradation d'un composant dans le processus étudié, où un ensemble de caractéristiques est extrait ou combiné pour représenter telle mesure [8]. La procédure de construction de HI et l'évaluation de son adéquation représentent des étapes ardues envers la réalisation d'un indicateur fiable. D'une manière générale, nous distinguons deux types d'indicateurs, l'Indicateur Physique (PHI) extrait de la physique des pannes et l'Indicateur Virtuel (VHI) résultant de la fusion d'un ensemble de PHI ou de signaux délivrés par des capteurs [4].

1.2.2.3 Durée de vie utile restante (Remaining useful life)

La durée de vie utile restante (RUL) désigne le temps resté pendant lequel un composant ou un système continue à remplir sa fonction. La prédiction du RUL donne aux utilisateurs la possibilité de prolonger la durée de vie utile du système et d'atténuer le niveau des risques [2]. Le terme RUL est utilisé par les ingénieurs et les praticiens du domaine PHM avec différents termes, notamment la fatigue dans le domaine du mécanique, la vitesse de propagation des fissures dans la modélisation théorique et le taux d'usure pour les composants de machine. Dans l'ingénierie des matériaux, les chercheurs parlent du taux de corrosion où de la durée de vie et les politiques de remplacement sont liés au domaine de maintenance [9].

La figure 1.1 présente le processus de pronostic, y compris les concepts définis ci-dessus. Les états de fonctionnement normal, dégradé et critique sont déterminés. En outre, d'autres critères importants, notamment le cycle actuel, le seuil et la fin de vie du système (EoL) sont décrits.

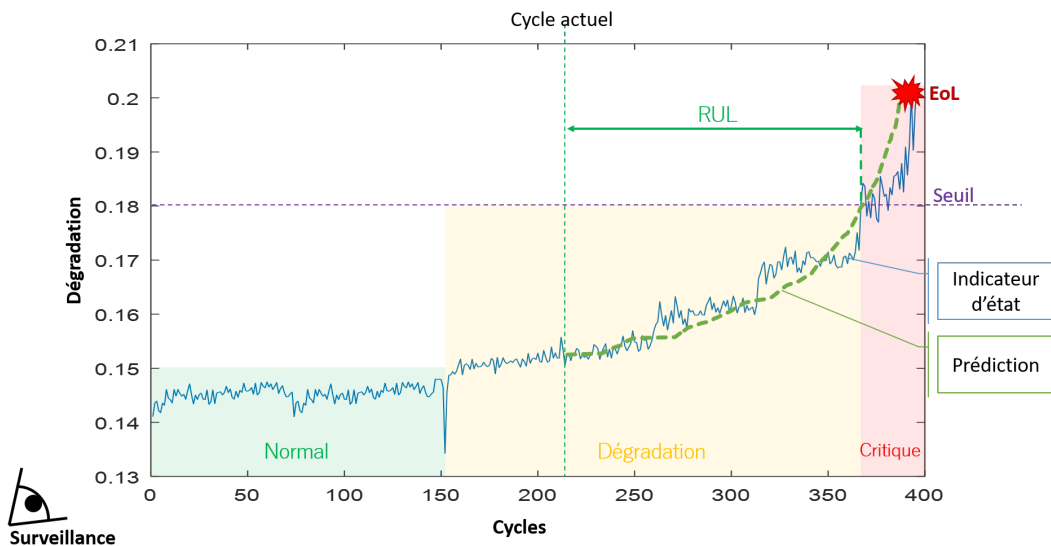


FIGURE 1.1 – Illustration de différents concepts de pronostic

1.3 Différentes approches du pronostic

Depuis l'introduction de la notion de PHM dans le domaine industriel, de nombreuses approches ont été développées. La figure 1.2 présente les différents types d'approches du pronostic disponibles dans la littérature.

1.3.1 Approches basées sur un modèle physique

Les approches basées sur un modèle supposent la disponibilité d'un modèle physique qui est une représentation mathématique reflétant le comportement de dégradation d'un système. En général, le modèle physique est issu de principes, d'expériences, de lois physiques connues, de méthode de similitude, d'analyse dimensionnelle et de prototypage.

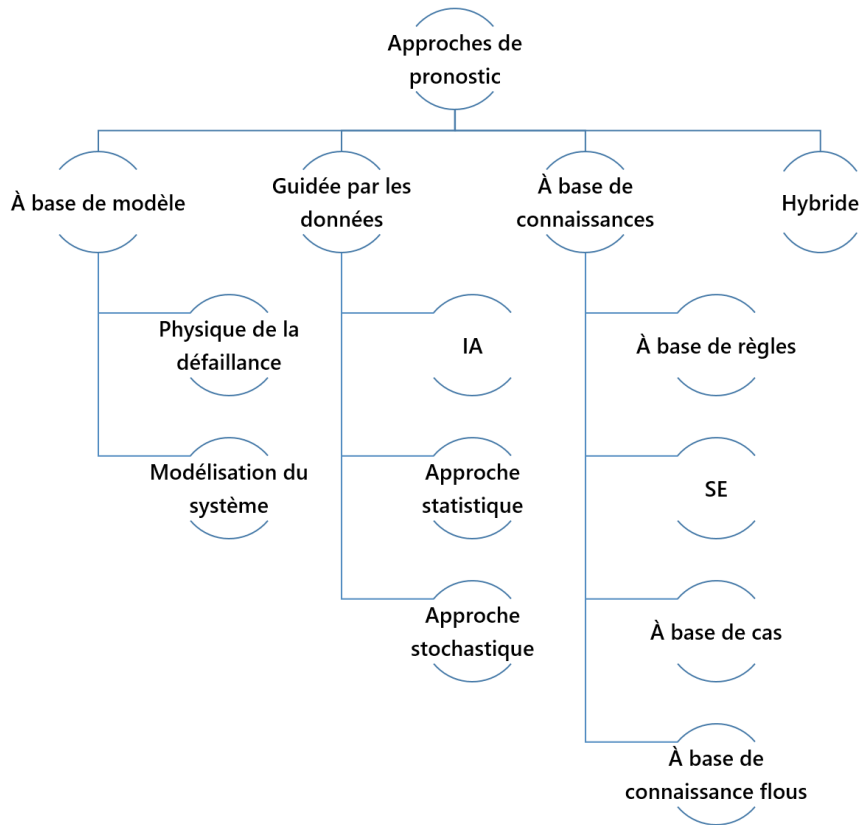


FIGURE 1.2 – Classification des approches du pronostic

Aussi, il est déterminé en cas de disponibilité des données de dégradation [10]. La compréhension de la physique des défaillances, connaissance sur le système, les conditions de fonctionnement et les charges du cycle de vie sont nécessaires pour développer un modèle physique solide [11]. A titre d'exemple, pour appliquer le modèle de croissance des fissures, nous avons besoin de la géométrie des matériaux, les charges opérationnelles et les conditions environnementales [12]. De plus, une connaissance approfondie des phénomènes de fissures est une étape essentielle pour l'application de ce modèle. Cependant, le modèle physique en pratique n'est pas disponible ou incomplet et les conditions d'utilisation future sont incertaines, ce qui rend difficile l'adoption de ce type d'approches [2]. Généralement ces approches peuvent être appliquées pour des problèmes de prédiction à court ou à long terme [13]. La figure 1.3 présente un organigramme général de l'adoption de telles méthodes [14].

Dans les lignes suivantes, nous présentons les classes principales des approches à base de modèles.

1.3.1.1 Classification des approches basées sur un modèle physique

Deux classes d'approches basées sur le modèle physique peuvent être distinguées dans la littérature, la physique de la défaillance et la modélisation du système [5].

1. Physique de la défaillance - Physics of Failure (PoF)

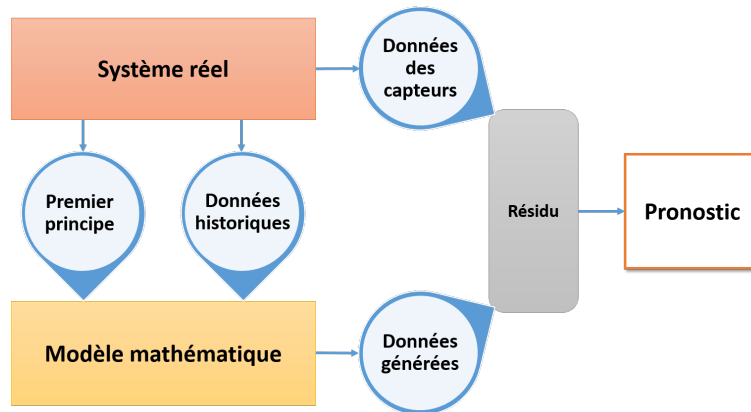


FIGURE 1.3 – Organigramme d'approche basée sur un modèle physique

Ce type d'approches aborde les principales causes de défaillance telles que la corrosion en se concentrant sur la durée de vie du système et l'aspect de fiabilité de composant. Par conséquent, les méthodes PoF sont spécifiques aux composants tels que le modèle de fissure. Elles permettent, dans les conditions de fonctionnement actuelles, d'évaluer la fiabilité de système [5, 10].

2. Modélisation du système

Dans cette classe d'approches, le composant sous dégradation est démontré par un modèle qui peut présenter le comportement stochastique du système. Le modèle d'espace d'état est l'une des méthodes adoptées dans ce type de techniques où il est basé sur les équations différentielles qui représentent le modèle par un ensemble d'entrées, de sorties et de variables d'état [5].

1.3.1.2 Avantages et inconvénients

Les principaux avantages des approches à base de modèles sont [2, 10, 15, 16] :

- **Prédiction à long terme** : Prédiction précise en dehors des données d'apprentissage en extrapolant le modèle physique jusqu'à ce que la dégradation atteigne le seuil défini ;
- **Petit nombre de données** : nécessite une quantité de données relativement faible et beaucoup moins que le modèle basé sur les données ;
- **Robustesse** : Possibilité d'application pour différentes conditions d'exploitation si les paramètres du modèle sont identifiés avec précision ;
- **Généralisation** : Capacité d'adaptation ou de validation à nouveaux systèmes ayant le même type et la même configuration ;
- **Lisibilité** : Compréhension du système et de la physique de la dégradation ce qui simplifie la certification et la justification de modèle développé ;
- **Signification physique** : L'indicateur d'état et le modèle de dégradation associés ont une signification physique ;
- **Précision** : Exactitude et précision élevées si le modèle physique est bien défini.

Malgré les avantages obtenus lors de l'adoption de ce type d'approches, certaines limitations critiques peuvent être remarquées [1, 5, 7, 9, 10, 15, 16] :

- **Connaissances sur le système** : Connaissances sur la physique fondamentale, les conditions de fonctionnement et l'environnement du système sont requises ;
- **Coût d'implémentation** : Consommation de temps et de calcul élevée en raison du manque d'approches de modélisation et de la complexité de modélisation ;
- **Dépendance** : Dépendance élevée du modèle mathématique au domaine d'expérience dans lequel une exploration exhaustive du comportement de dégradation est requise ;
- **Difficulté de modélisation** : La corrélation entre les variables du système et les facteurs externes rend leur modélisation et leur estimation très difficiles. De plus, certains comportements de dégradation ne peuvent pas être modélisés et la présence de relations non linéaires et discrètes rend le processus de modélisation difficile ;
- **Difficulté de généralisation** : La dépendance de la robustesse des approches à une défaillance spécifique et aux conditions expérimentales limite leur réutilisabilité ;
- **Complexité** : La difficulté de comprendre la physique du système et le comportement de dégradation implique la prise en compte d'une phase simplificatrice.

1.3.1.3 Techniques

L'approche à base de modèles est fondée sur la présence d'un modèle mathématique d'un type de défaillance spécifique tel que le modèle de croissance de fissure et le modèle de croissance d'écaillage. Certains paramètres du modèle sont définis à base du domaine d'expérience ou mis à jour en continu en fonction de l'état des machines en temps réel [1]. Les approches principales de la technique basée sur les modèles sont :

a. Filtre à particules

Le filtre à particules est l'approche basée sur modèle la plus utilisée dans le domaine du pronostic, où la distribution postérieure des paramètres est modélisée sous forme de particules avec des poids. La méthode comprend trois étapes principales [17] :

- (a) Prédiction de l'état actuelle de défaillance en utilisant l'état précédent
- (b) mise à jour de l'état de défaillance et les paramètres du modèle
- (c) Ré-échantillonnage des particules où les échantillons de poids élevés sont dupliqués et les autres de poids faibles sont supprimés.

Les principaux avantages de la méthode sont sa précision élevée, applicabilité aux problèmes non linéaires avec un bruit non gaussien et son élimination par rééchantillonnage du problème de dégénérescence. La définition du modèle et le coût de calcul élevé sont parmi les inconvénients de la méthode [18]. Un guide pratique de l'approche dans le domaine du pronostic en utilisant le code Matlab est fourni par An et al [19].

b. Filtre de Kalman

Le filtre de Kalman (Kf) est un estimateur de traitement du signal récursif développé pour prédire l'état optimal dans les modèles linéaires en utilisant les estimations de l'état actuel et les mesures des capteurs prises au fil du temps. La procédure d'optimisation dans le filtre de Kalman est basée sur la minimisation de l'erreur de covariance en supposant une distribution gaussienne pour tous les processus [3]. Dans le cas des systèmes non linéaires, une extension du filtre de Kalman connue sous le nom de filtre de Kalman étendu (EKf) est proposée où la non-linéarité est obtenue en rapprochant la moyenne et la covariance actuelles [20]. La sensibilité au bruit et la nécessité de définir avec précision le modèle sont les limites principales de la méthode [18].

c. Modèle de Paris-Erdogan (PE)

Le modèle de Paris est l'une des approches à base de modèle les plus adoptées dans le domaine du PHM. Ce modèle a été proposé pour la première fois pour décrire la croissance des fissures et adopté plus tard pour d'autres problèmes [4]. En considérant certaines hypothèses, le taux de croissance des fissures peut être décrit dans le modèle PE par [2] :

$$\frac{da}{dN} = c(\Delta\sigma\sqrt{\pi a})^m$$

où a est la moitié de la taille de fissure, N désigne le nombre de cycles. C et m sont des paramètres spécifiques du modèle. Un exemple pratique d'application utilisant le modèle de Paris sous Matlab est présenté par Kim et al [2].

d. Méthode bayésienne

La méthode bayésienne (BM) est basée sur le théorème de Bayes où la distribution postérieure des paramètres de l'état actuel est obtenue à l'aide d'une équation unique et de la multiplication de toutes les fonctions de vraisemblance des données mesurées. A ce niveau où l'expression de la distribution postérieure est choisie, une phase d'échantillonnage est réalisée pour générer des échantillons à partir de la distribution postérieure. Dans les problèmes pratiques, la distribution postérieure en général ne suit pas la distribution standard, pour ce faire, une méthode d'échantillonnage est nécessaire pour générer des échantillons [2, 17].

Le tableau 1.1 présente quelques applications de techniques populaires à base de modèle et leurs exigences principales.

TABLE 1.1 – Quelques applications des approches basées sur le modèle physique

Approche	Exigences	Techniques	Références
Physique de défaillance	Modèle physique spécifique Compréhension des mécanismes de défaillance	Creep, Fatigue and Wear models	[15]
		Damage models (bearing, Gear)	[21]
		Finite element model of a helicopter transmission	[22]
		Markovian Fractional Brownian Motion (FBM)	[23]
Modélisation de système	Démonstration du modèle mathématique Données historiques (utiles)	Particle filter	[24-27]
		(Extended) Kalman filter	[28-32]
		Paris-Erdogan model	[33-35]

1.3.2 Approches guidées par les données

La complexité des systèmes, la diversité et l'incertitude des conditions environnementales et le développement croissant de nouveaux produits et de nouvelles technologies rendent l'adoption d'approches basées sur un modèle physique plus difficile. Par conséquent, l'avènement de l'IA fait des techniques guidées par les données un paradigme de pronostic potentiel et efficace [36]. Ces approches sont les plus utilisées parmi les méthodes de pronostic existantes et ont gagné beaucoup d'importance ces dernières années. De nombreuses données historiques, informations opérationnelles et données externes sont mesurées et enregistrées dans les systèmes modernes. Grâce à ces données, les approches orientées données peuvent identifier les paramètres d'état actuels du système et prédire le comportement futur [2, 37]. Dans ce type de méthodes, la dégradation de la défaillance est extraite directement des données fournies en utilisant un ensemble de caractéristiques sélectionnées [7]. D'un point de vue théorique, l'approche basée sur le modèle est plus préférable en raison de sa précision et de sa capacité de prédiction en temps réel. Cependant, dans la pratique, les approches guidées par les données sont plus adoptées en raison de leur facilité d'utilisation et leur souplesse de déploiement [11]. Le cadre général de la méthode guidée par les données est illustré sur la figure 1.4.

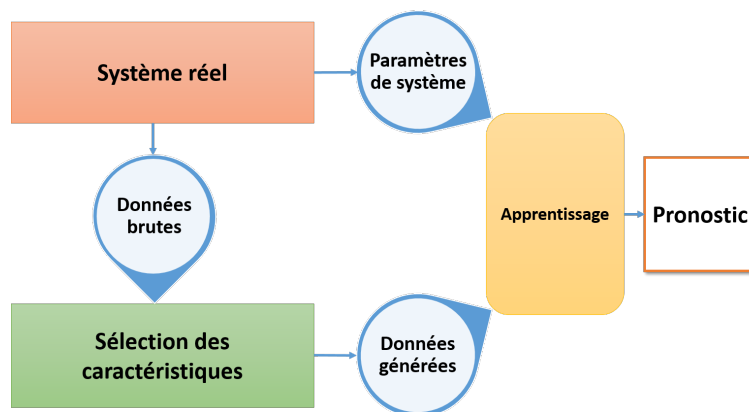


FIGURE 1.4 – Cadre de l'approche guidée par les données

1.3.2.1 Classification des approches guidées par les données

Parmi les différentes classifications des approches orientées données existant dans la littérature [5, 10, 17, 37], nous distinguons trois grandes catégories :

1. Approches d'intelligence artificielle (apprentissage automatique)

Les méthodes d'intelligence artificielle ou leur sous-domaine les techniques d'apprentissage automatique tentent d'apprendre le comportement de dégradation d'un système à partir des données disponibles en utilisant des méthodes d'IA spécialisées. Ces méthodes ont la capacité d'apprendre le mécanisme de dégradation des systèmes complexes et de prédire le RUL en extrapolant la dégradation au seuil défini [4, 37, 38].

2. Approches statistiques ou méthodes probabilistes

La méthode statistique ou probabiliste tente d'analyser le comportement de dégradation considéré comme une variable aléatoire basée sur les données fournies à l'aide d'une analyse statistique. Ce type d'approches analyse les propriétés statistiques des données de surveillance, et compare les critères statistiques actuels avec la nouvelle observation. Cette observation sera considérée comme anomalie si elle ne représente pas les propriétés statistiques connues [37, 39]. Plus de détails sur l'approche statistique peuvent être trouvés dans Si et al [40].

3. Approches stochastiques

Le modèle stochastique traite les informations de fiabilité telles que temps moyen de bon fonctionnement avant défaillance (MTTF) comme une variable aléatoire ou une probabilité de défaillance. Cette classe d'approches est basée sur l'hypothèse que les temps de défaillance des systèmes identiques peuvent être décrits par des variables aléatoires indépendantes et identiques représentées par une fonction de densité de probabilité [41]. Le RUL est obtenu en prédisant leur distribution de probabilité dégradée dans le temps avec une quantification de l'incertitude des résultats [38]. Le processus de Markov, le processus Gaussien sont des exemples de processus stochastiques formant l'élément constitutif principal des modèles stochastiques [37].

Ces dernières années, les algorithmes d'apprentissage profond, qui constituent une branche de l'IA, ont suscité une attention accrue et prouvé leur efficacité dans de nombreux domaines. Ce type de modèle peut traiter des données très complexes et non linéaires à l'aide d'un réseau neuronal profond sans avoir recours à la connaissance du domaine et sans avoir besoin d'extraire et de sélectionner des caractéristiques explicites. Par conséquent, il est considéré comme un outil de pronostic efficace en présence de données brutes de haute dimension où certaines tâches de PHM telles que le traitement des caractéristiques sont intégrées dans l'architecture profonde [42, 43]. Les étapes principales de ce type d'architectures sont : l'acquisition des données, l'apprentissage, la construction d'un modèle prédictif intelligent et enfin la prédiction [42].

1.3.2.2 Avantages et inconvénients

Comme toute méthode de pronostic, l'approche guidée par les données a ses propres avantages, dont les principaux sont présentés ci-dessous [1, 2, 5, 9, 11, 16, 39, 44] :

- **Facilité d'utilisation** : Pratiquement, les approches pilotées par les données sont rapides et faciles à utiliser en raison de la disponibilité de nombreux packages de traitement de données et d'apprentissage automatique;
- **Auto-apprentissage** : Aucune connaissance approfondie des algorithmes d'apprentissage automatique est requise et leur disponibilité et simplicité de compréhension encouragent les chercheurs et les débutants à mettre en œuvre ce type de techniques;
- **Connaissance sur le système** : Les approches guidées par les données ont la capacité de capturer des comportements complexes sans aucune ou rare connaissance de la physique du système et de ses conditions de fonctionnement;

- **Faible coût** : Les méthodes basées sur les données ont un faible coût de mise en œuvre et de développement d'algorithmes, car elles ne nécessitent pas d'étude physique;
- **Robustesse** : Ces méthodes ont une capacité de prédiction pour des données dimensionnelles et bruitées sans altération considérable par les conditions de fonctionnement;
- **Précision** : Elles ont également une capacité de prédiction précise à court terme et de réduction des erreurs de modèle;
- **Généralisation** : Les méthodes basés sur les données peuvent être adaptés pour d'autres systèmes dans lesquels le comportement de dégradation peut être appris.

Malgré l'utilisation réussie des approches guidées par les données dans le domaine du pronostic, certaines limites et inconvénients existent. Nous pouvons citer [2, 5, 9, 16, 39, 44] :

- **Prévision à court terme** : Aucune preuve de réussite générale concernant la prédiction à long terme n'est fournie;
- **Grande quantité de données** : La présence d'une quantité suffisante de données est la principale exigence de l'approche basée sur les données pour être précise;
- **Absence de transparence et de signification physique** : Manque de transparence sur la façon dont la décision est prise et aucune explication physique sur les causes du problème;
- **Gestion de l'incertitude** : Nécessité d'algorithmes de gestion de l'incertitude pour contrôler les résultats prédits;
- **Sur-apprentissage** : La précision est affectée par les problèmes de sur-apprentissage et de sur-généralisation;
- **Dépendance de la précision** : La précision dépend fortement de la qualité et de la taille des données disponibles.

1.3.2.3 Techniques

Un ensemble de techniques guidées par les données adoptées dans le domaine du PHM est présenté dans cette sous-section.

a. Réseaux de neurones artificiels

Le RNA vise à imiter le cerveau humain en connectant un ensemble de nœuds dans une architecture complexe. Il est considéré comme la technique de l'IA la plus utilisée dans le pronostic, en raison de sa bonne capacité d'approximation des systèmes non linéaires. Le RNA tente d'apprendre la relation entre l'indicateur d'état et le RUL en utilisant les données fournies. Les inconvénients majeurs de RNA sont leur faible transparence, la nécessité d'un grand nombre de données et le choix du nombre de couches et de nœuds [4, 7].

b. Régression par processus gaussien

La régression par processus gaussien (GPR) est une technique d'IA considérée comme une méthode probabiliste et non paramétrique basée sur le processus gaussien. Un modèle GPR est défini par sa fonction moyenne et sa fonction de covariance [45]. L'un des avantages de la technique GPR est sa capacité de prédire le RUL avec un petit ou un grand jeu de données, alors que le principal problème est son calcul lourd [4]. Une extension de GP connue sous le nom de processus gaussien inverse est proposée pour modéliser la dégradation des systèmes hétérogènes avec un environnement aléatoire [46]. Pour plus de détails sur la méthode GP, le lecteur peut se référer au fameux livre de Rasmussen intitulé « Gaussian process for machine learning » [45].

c. Machine à vecteurs de support

La machine à vecteurs de support est une technique d'IA largement utilisée dans le domaine du pronostic et fondée sur la théorie statistique. Elle a la capacité de fournir une solution unique et n'est pas sujette aux minima locaux. Contrairement aux RNA, la méthode SVM est plus adaptée aux problèmes du PHM avec une taille des données petite ou limitée. En introduisant la prédiction probabiliste dans la méthode SVM, une nouvelle version appelée Relevance Vector Machine (RVM) est proposée pour surmonter les limites de la technique SVM. Les inconvénients critiques des méthodes SVM et RVM sont la forte dépendance de leurs performances au choix de la fonction noyau et la sélection des paramètres [4, 7].

d. Processus de Wiener

Le processus de Wiener est utilisé pour modéliser la variabilité temporelle du comportement de dégradation dans un processus où le bruit est estimé d'être un mouvement brownien aléatoire. Le processus de Wiener est basé sur l'hypothèse que l'état futur du composant dépend de l'état actuel sans aucune dépendance avec le comportement dans le passé. En général, la PDF de RUL est difficile à obtenir analytiquement dans l'approche de Wiener dans laquelle une solution approximative est nécessaire [4, 47]. Pour une application plus poussée du modèle de dégradation conventionnel basé sur le processus de Wiener, le lecteur est invité à consulter le travail de Zhang et al [47].

e. Chaînes de Markov et chaînes de Markov cachées

Les chaînes de Markov sont une séquence d'états en nombre fini où chaque état ne dépend que de l'événement immédiatement précédent. Dans le domaine du PHM, le processus de dégradation dans la chaîne de Markov est supposé être transformé en états à base du principe de Markov. Le modèle de Markov caché (HMM) est une extension représentant la séquence stochastique du système avec une chaîne de Markov où les états sont supposés d'être cachés. Les HMM sont applicables aux systèmes non linéaires et non stationnaires. Deux types de HMM sont reconnus, les HMM discrets conçus pour la modélisation des observations discrètes et un second type opté pour les observations continues connu sous le nom de HMM continus [4, 20].

f. Modèles d'apprentissage profond

L'introduction d'algorithmes d'apprentissage profond dans le domaine du PHM a attiré beaucoup d'attention ces dernières années en raison de leur succès dans nombreux

domaines. En outre, la présence d'un grand nombre de données collectées dans les systèmes de fabrication, tels que les signaux de vibration, motivent l'adoption de ces approches. Parmi les architectures d'apprentissage profond proposées dans la littérature, nous pouvons distinguer quatre modèles largement utilisés dans le domaine du PHM : le réseau neuronal récurrent (RNN), la machine de Boltzmann restreinte (RBM), l'encodeur automatique (AE) et le réseau neuronal convolutif (CNN) [48].

D'autres modèles guidés par les données proposés et adoptés dans le domaine du PHM peuvent être distingués, notamment le modèle autorégressif (AR) le modèle du processus gamma, les réseaux bayésiens (BN), le modèle de Gray, etc...

Le tableau 1.2 présente quelques applications des modèles guidés par les données, y compris leurs principales exigences. Ce tableau peut donner un aperçu global concernant la classification de ces modèles.

TABLE 1.2 – Quelques applications des méthodes guidées par les données

Approches	Exigences	Techniques	Références
Intelligence artificielle (Apprentissage automatique)	Historique de données Extraction et sélection de caractéristiques dans le traitement des données Compétences en apprentissage automatique	ANN	[49-53]
		GPR	[54-57]
		SVM	[58-65]
		LR, MLP	[66]
Intelligence artificielle (apprentissage profond)	Grand jeu de données historiques Compétences en apprentissage profond	Extreme learning machine	[67]
		CNN	[68]
		DCNN	[69]
		DNN	[70]
		LSTM	[71]
		Semi-supervised deep learning	[72]
		RNN	[73]
LFGRU	[74]		
Modèles statistiques	Historique de données Compétences en statistiques et probabilités	Transfer learning	[75]
		Autoregressive model	[76-79]
		Gamma process	[80, 81]
Modèles stochastiques	Historique de données Compétences en statistiques et probabilités	Proportional hazards model	[82-84]
		Wiener process	[47, 85, 86]
		(Hidden) Markov model	[87-89]
		Bayesian method	[90, 91]

1.3.3 Approches basées sur l'expérience ou la connaissance

Approches basées sur l'expérience, basées sur la connaissance ou sur la fiabilité statistique, différentes appellations pour la même classe d'approches de pronostic sont adoptées pour les composants critiques, non surveillés et sans modèle physique [11]. Ce type de méthodes est développé sur la base de l'expérience et les connaissances des experts pour prédire le RUL en analysant la similarité entre les données d'expérience collectées et les situations observées (Figure. 1.5). Elle se base initialement sur les données d'expérience historiques fournies, incluant la moyenne des défaillances de composant étudié [10, 11]. Les connaissances et l'expérience peuvent être présentées par des faits, des règles ou des cas recueillis au fil des années d'exploitation et de maintenance des composants techniques. Les

faits, les cas et les règles sont utilisés pour décrire la dégradation et les défaillances et prédire les futures défaillances potentielles en utilisant des techniques intelligentes [37]. L'analyse de Weibull, les lois de Poisson et les modèles statistiques log-normaux sont d'autres exemples adoptés dans les approches basées sur l'expérience [11].

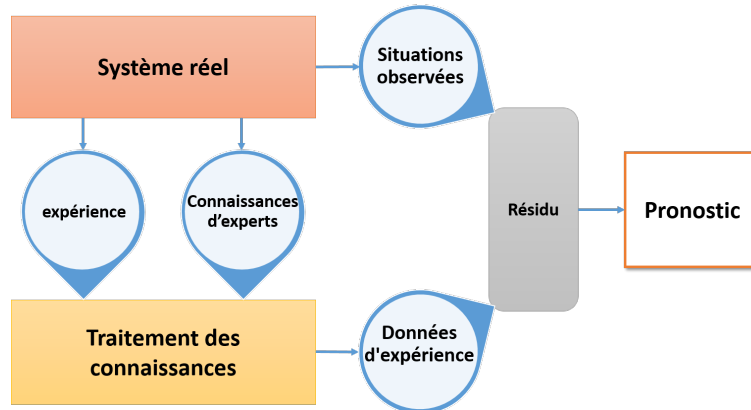


FIGURE 1.5 – Cadre d'approche basée sur les connaissances

1.3.3.1 Classification des approches basées sur l'expérience

Quatre classes principales d'approches basées sur l'expérience sont présentées ci-dessous :

1. Modèle à base de règles

Le modèle à base de règles est représenté par un ensemble de règles "si-alors" dans le but d'imiter le raisonnement humain. Les composants fondamentaux d'un modèle à base de règles sont : la base de connaissances, la base de faits et un moteur d'inférence utilisé pour déduire des nouveaux faits. Les règles sont définies par "Si conditions, alors résultats ou actions" et collectées durant le fonctionnement de système au fil des ans. Le moteur d'inférence utilise les faits initiaux pour déduire à base des règles existantes de nouveaux faits qui sont inclus comme une nouvelle entrée. La difficulté principale de ces méthodes est la construction de la base de connaissances qui doit être complète le plus possible sans aucune contradiction entre les règles [10, 37].

2. Système expert basé sur un modèle

Le système expert à base de modèle est proposé pour imiter le comportement et la dégradation d'un système industriel. Pour réaliser un pronostic à l'aide d'un système expert basé sur un modèle, trois étapes sont indispensables : la génération d'hypothèses, le test d'hypothèses et la discrimination d'hypothèses. La divergence entre le modèle établi et le système réel est corrigée jusqu'à ce que le comportement de dégradation dans le modèle développé reflète le processus de dégradation réel. À ce niveau, le modèle est prêt à accomplir la tâche de pronostic [10].

3. Modèle à base de cas

La représentation des connaissances dans un modèle à base de cas est réalisée par des connaissances sous la forme de (problème, solution) recueillies à partir d'expériences et de solutions de problèmes réels. Le travail principal des méthodes à base de cas

est la réutilisation de la même solution pour un nouveau problème tel qu'elle a été adopté dans le cas le plus similaire. La base de cas est enrichie par un nouveau cas si la solution est confirmée. Un point important des méthodes à base de cas par rapport aux techniques basées sur les règles est leur possibilité d'application en cas de difficulté de déclarer d'une manière explicite la relation entre les faits [37]. En outre, l'une des forces des systèmes à base de cas est l'amélioration de leur qualité au fur et à mesure que de nouveaux cas sont ajoutés et traités [10].

4. Modèles à base de connaissances floues

Les modèles à base de connaissances floues utilisent des règles "si alors" de la même manière que les techniques à base de règles, mais avec des déclarations floues. Dans les règles floues, les énoncés sont basés sur des termes linguistiques tels que : "haut", "bas", où une valeur de degré de vérité est introduite pour surmonter la théorie de la logique classique. Dans l'approche du pronostic flou, nous pouvons distinguer trois composantes principales : la base de connaissances, les règles floues et le moteur d'inférence. Deux étapes importantes sont nécessaires dans une telle méthode, les phases de fuzzification et de défuzzification. La première étape consiste à fuzzifier (transformer en floue) l'entrée réelle. Une fois que l'inférence est réalisée sur les entrées floues et génère des sorties floues, une étape de défuzzification est déclenchée pour produire des sorties interprétables à valeurs continues [10, 37]. Le modèle flou est introduit pour définir les règles de pronostic, classifier des défauts, traiter les perturbations et le bruit, gérer l'incertitude et traiter les variables continues [7].

1.3.3.2 Avantages et inconvénients

Les principales avantages de l'approche basée sur l'expérience sont énumérés ci-dessous [9, 12, 44] :

- **Simplicité de la programmation** : Aucune compétence rigoureuse en programmation ou de formulation des données n'est requise et simplicité du contrôle des paramètres ;
- **Aucun modèle requis** : Aucun modèle physique est requis ;
- **Raisonnement humain** : Remplacement de la prise de décision de l'expert humain et possibilité de comprendre les résultats et le processus de décision ;
- **Augmentation des performances** : Les problèmes résolus sont introduits comme une nouvelle expertise qui augmente la performance du système de pronostic ;
- **Gestion de l'incertitude** : L'introduction de la logique floue facilite la gestion de l'incertitude et le traitement des données inexacts et incomplètes.

Malgré les avantages de l'approche fondée sur l'expérience, nous pouvons distinguer certaines limites comme [9, 12, 14, 37, 44] :

- **Coût élevé** : Les expériences sont souvent coûteuses ;

- **Difficulté de la modélisation** : La conversion des connaissances en règles reflétant le sens souhaité est une tâche difficile et nécessite une certaine expertise. De plus, l'introduction de la logique floue dans les règles n'est pas toujours une mission facile ;
- **Généralisation** : Difficulté de traiter de nouveaux problèmes ou situations qui ne sont pas couverts par la base de connaissances ;
- **Sensibilité** : Simplicité des modifications apportées à la base de connaissances peut créer des erreurs dans le processus du SE ou provoquer des contradictions entre les règles ;
- **Explosion combinatoire** : Des problèmes de calcul peuvent survenir en cas de taille énorme de la base de connaissances ;
- **Dépendance de la précision** : La précision dépend fortement de la qualité et de la taille de la base de connaissances.

1.3.3.3 Techniques

Certaines techniques des méthodes basées sur les connaissances introduites dans la littérature sont présentées dans la sous-section suivante.

a. Systèmes experts

Les systèmes experts sont adoptés dans l'industrie pour traiter des problèmes qui sont habituellement résolus par des experts humains. Les SEs sont définis comme un programme informatique conçu pour surveiller un système industriel et prendre une décision en cas de nouvelle situation. Les connaissances des experts accumulées au fil d'années sont stockées dans l'ordinateur sous forme de règles pour simuler le raisonnement de l'expert humain. Les règles sont stockées dans une base de connaissances où un moteur d'inférence est opté pour déduire des solutions par l'examen des règles existantes. La phase difficile dans la construction des SEs est la construction de la base de connaissances qui implique deux phases : l'acquisition de connaissances et leur représentation où certaines compétences sont nécessaires [14, 44].

b. Systèmes flous

Depuis sa proposition, la logique floue a été exploitée dans le contexte de nombreux systèmes. Le point principal des systèmes flous est l'introduction de la logique floue dans la modélisation des règles qui peuvent représenter des informations bruitées, imprécises ou ambiguës. Basée sur la théorie des ensembles flous, la logique floue peut facilement modéliser le comportement de dégradation et fournir des décisions similaires au raisonnement humain. En général, la logique floue dans les systèmes flous de pronostic est intégrée avec d'autres méthodes telles que le SE et le RNA ce qui conduit à des modèles hybrides comme c'est le cas de SE floue ou RNA floue [14, 44].

Nous soulignons dans le tableau 1.3 quelques applications des techniques basées sur la connaissance et leurs exigences centrales.

TABLE 1.3 – Quelques applications de modèles basés sur la connaissance

Approches	Exigences	Techniques	Références
Modèles basés sur des règles	Données d'expérience Compétences en IA	Système à base des règles	[92-95]
Système expert basé sur un modèle	Données d'expérience Compétences en IA	Système à base de connaissance	[96]
Modèles basés sur des cas	Données d'expérience Compétences en IA	Raisonnement à base des cas	[97, 98]
Modèles à base de connaissances floues	Données d'expérience Compétences en IA Compréhension de la logique floue	Système de connaissance floue	[99, 100]

1.3.4 Approches hybrides

La complexité des systèmes industriels implique une augmentation du nombre et de la complexité des défauts et des modes de défaillance, du type et de taille des données brutes collectées et de la difficulté de la modélisation physique. En raison de la complexité croissante des systèmes industriels et de la miniaturisation des composants, les approches simples deviennent de plus en plus complexes et ne parviennent pas à prévoir les défaillances de manière robuste. Pour surmonter ces inconvénients et éviter la limitation de l'adoption simple de méthodes, la combinaison de plusieurs modèles est considérée comme une solution potentielle [37]. Les approches hybrides, combinées, d'ensemble, multi-modèles et de fusion dénotent la même signification d'intégrer d'une certaine manière différentes méthodes. L'idée principale des approches hybrides est de combiner deux ou plusieurs méthodes dans le but d'intégrer leurs mérites et d'éviter leurs limites. En outre, plus d'un défaut peut se produire simultanément dans les systèmes complexes et différents types de données peuvent être collectés, d'où l'utilisation d'une méthode hybride peut fournir une meilleure solution [7, 18]. À titre d'exemple, un modèle physique peut être adopté dans une approche guidée par les données pour définir le modèle mathématique [2]. La combinaison des méthodes de pronostic peut être utilisée pour l'extraction ou l'examen des données, la modélisation de la dégradation ou l'estimation du RUL [14].

1.3.4.1 Configurations des approches hybrides

Trois architectures principales de combinaison peuvent être construites dans lesquels des stratégies plus complexes peuvent être déduites en utilisant ces trois points de base. Les trois configurations possibles sont : combinaison en série, combinaison en parallèle et combinaison embarquée [37]. La Figure 1.6 met en évidence la présentation graphique de ces configurations de base dont les fonctions principales sont présentées dans les sous-sections suivantes.

1. Modèles en série

Deux modèles de pronostic sont considérés comme étant en série si les résultats fournis par le premier sont utilisés comme entrée pour le second modèle. Par exemple, la

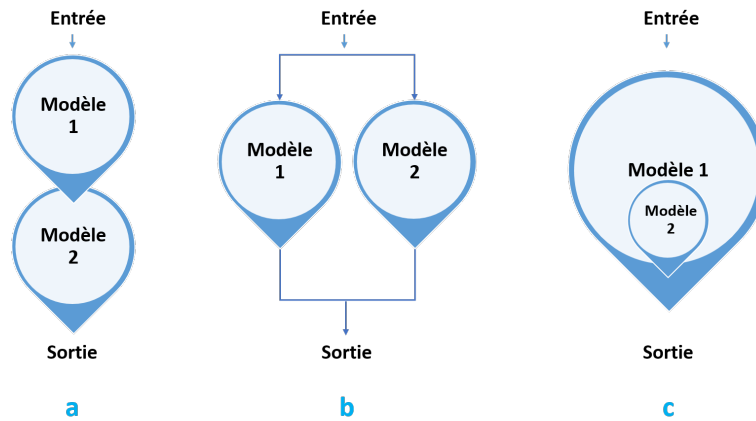


FIGURE 1.6 – Configurations des méthodes hybrides

méthode basée sur un modèle physique est utilisée comme modèle ayant une connaissance préalable du système et la méthode basée sur les données est adoptée pour estimer les paramètres non mesurables [101, 102]. Certains chercheurs ne considèrent pas le modèle en série comme une approche hybride en raison de l'absence de coopération mutuelle entre les techniques fusionnées pour obtenir les valeurs de sortie [37]. Une vue schématique de l'approche en série est présentée sur la figure 1.6.a.

2. Modèles en parallèles

Deux méthodes de pronostic sont considérées en parallèles si elles utilisent des données d'entrée identiques ou connexes et fournissent des résultats de sortie compétitifs. Les modèles combinés peuvent partager les mêmes données ou des entrées connexes différentes, le premier traitant les valeurs numériques des capteurs alors que le second est adopté pour le traitement des connaissances. Les sorties fournies par les approches combinées sont fusionnées ou filtrées afin de fournir des résultats plus précis [37]. La figure 1.6.b illustre le schéma des approches parallèles.

3. Modèles embarqués

Dans la vision des modèles embarqués, l'un des modèles combinés est intégré comme sous-partie dans le second modèle. Dans cette configuration, le modèle intégré est introduit pour réaliser certaines tâches internes qui ne sont pas vérifiées par le modèle principal. Comme exemple de mise en œuvre, le système d'inférence floue est introduit avec succès dans de nombreuses méthodes telles que les RNAs qui aboutit au développement de systèmes neuro-flous [37]. L'architecture des modèles embarqués est illustrée sur la figure 1.6.c.

1.3.4.2 Stratégies de combinaison

Différentes approches hybrides peuvent être obtenues en combinant les méthodes de pronostic présentées, comme le montre la figure 1.7. Dans les sous-sections suivantes, nous examinons en détail les stratégies possibles.

1. Approches multiples basées sur un modèle physique (P+P)

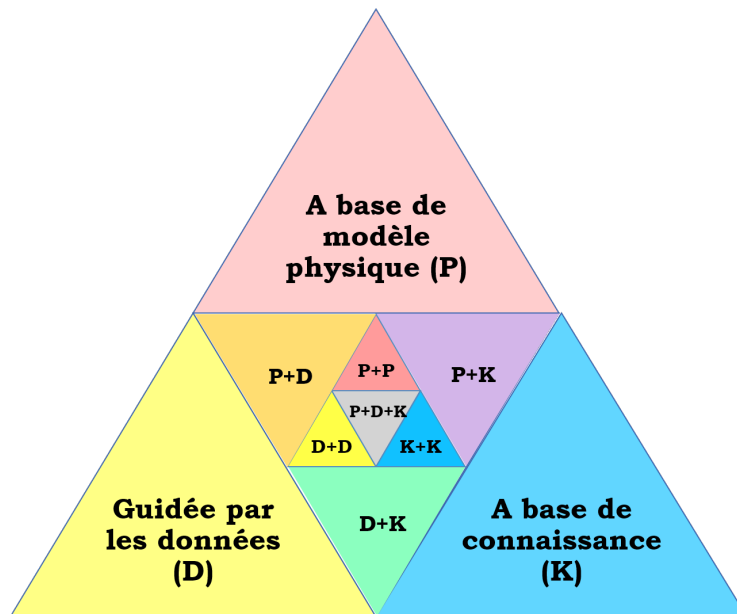


FIGURE 1.7 – Combinaisons hybrides possibles des approches de pronostic

En général, ce type de combinaisons est ciblé dans le but d'augmenter la précision et d'obtenir une bonne présentation physique de la dégradation. La plupart des approches multiples sont adoptées dans une combinaison en série. La première est introduite pour contrôler l'état du système et la seconde est choisie pour prédire le RUL. L'estimation de l'état du système dans des cas réels à l'aide de ce type d'approches n'est pas préférée en raison de sa complexité et de sa coût croissant et il exige une connaissance approfondie de la physique du système [37].

2. Approches multiples guidées par les données (D+D)

De la même manière de la stratégie précédente, les approches multiples guidées par les données tentent à améliorer le pronostic en combinant les avantages des méthodes concurrentes. La forme hybride de cette vision peut être obtenue en fusionnant les résultats fournis par les approches combinées. Pour la configuration en série, une approche peut être sélectionnée pour estimer l'état de système et une autre est choisie pour extrapoler le comportement de dégradation futur et prédire le RUL. Le RNA est la technique la plus adoptée dans ce type d'hybridation [12, 18, 37].

3. Modèles multiples à base de connaissances (K+K)

Des techniques multiples basées sur des connaissances sont introduites pour obtenir un bon raisonnement en pronostic pour les systèmes complexes en combinant différentes stratégies de raisonnement. La combinaison de plusieurs techniques basées sur la connaissance n'est pas largement adoptée en raison de leur difficulté de réalisation. La tâche difficile dans l'application de l'approche basée sur la connaissance est la construction de la base de connaissance qui génère multiples difficultés et défis lors de l'examen des stratégies hybride [37].

4. Stratégie intégrant un modèle physique avec un modèle guidé par les données (P+D)

Ce type d'approches hybrides est le plus souvent utilisé dans la littérature en raison de la popularité croissante de la méthode guidée par les données ces dernières années [37]. Les deux méthodes peuvent être utilisées en parallèle ou en série où une technique pilotée par les données est utilisée pour estimer l'indice d'état et la méthode basée sur un modèle physique est réservée à la prédiction du RUL [1]. Sur la base des classes de méthodes guidées par les données, trois combinaisons principales de méthodes physiques hybrides peuvent être discernées, à savoir [37] :

- Techniques d'IA combinées avec des méthodes basées sur un modèle physique;
- Modèle statistique tels que le SVM avec une méthode basée sur un modèle physique;
- Modèle stochastique combinés à une méthode basée sur un modèle physique.

Liao et al [12], donnent quatre grandes combinaisons possibles de modèles basés sur un modèle physique avec des méthodes pilotées par les données :

- Introduction d'une méthode guidée par les données pour déduire le modèle de mesure où la méthode basée sur un modèle physique est adoptée pour prédire Le RUL;
- Méthode guidée par les données choisie pour remplacer le modèle du système dans la technique basée sur un modèle physique;
- Estimation des mesures futures à l'aide de l'approche basée sur les données et prédiction de la durée de vie utile par la technique basée sur un modèle physique;
- Fusionner les sorties prédites fournies par les méthodes combinées.

5. Stratégie intégrant un modèle physique avec un modèle basé sur les connaissances (P+K)

Dans cette stratégie de combinaison, les résultats fournis par la technique basée sur la connaissance peuvent être utilisés comme auxiliaire pour améliorer la capacité de la méthode basée sur un modèle physique. De plus, la méthode basée sur la connaissance peut être sélectionnée pour estimer l'état réel du système étudié alors que la méthode basée sur un modèle physique est réservée à la tâche de prédiction [12, 18]. En général, ce type de combinaison est adopté dans le domaine de la maintenance prédictive dans lequel des résultats explicatifs élevés sont offerts en rassemblant l'explication physique et le raisonnement d'experts. Cependant, le principal inconvénient de cette méthode hybride est sa combinaison de la complexité de la modélisation physiques et de la difficulté de la construction de la base de connaissances [37].

6. Stratégie intégrant un modèle guidé par les données avec un modèle basé sur les connaissances (D+K)

La puissance de la méthode basée sur la connaissance en fournissant un raisonnement d'expert est introduite pour couvrir la limitation de la technique pilotée par les données dans l'explication de la façon d'obtention des résultats. En outre, la capacité de la méthode guidée par les données à traiter des données numériques est introduite pour

surmonter la difficulté de la méthode basée sur la connaissance à traiter des valeurs continues [12, 18]. La puissance du modèle résultant dans une telle combinaison réside dans sa capacité de traitement des données hybrides, textuelles et numériques [37].

7. Stratégie intégrant un modèle basé sur la physique avec un modèle basé sur les données et un modèle basé sur les connaissances (P+D+K)

L'objectif principal de la construction de ce modèle est de tirer profit des principaux privilèges des trois approches de pronostic. Il tient compte de la signification physique de la méthode basée sur un modèle physique, la capacité du modèle basé sur les données à traiter les données numériques et l'explicabilité de la technique basée sur la connaissance. Par conséquent, un modèle hybride dans cette catégorie fusionne trois types d'informations : la physique du système, les données de dégradation, et le retour d'information sur la maintenance et l'intervention d'un expert. Cette catégorie est la technique extrêmement difficile parmi les dernières approches multi-modèles présentées. La complexité de la modélisation et de la construction d'une architecture valable du modèle hybride est le principal défi de ce type de modèles combinés. D'autres défis sont abordés davantage dans la façon dont les informations hétérogènes seront fusionnées et incluses comme entrées et comment les résultats dissemblables fournis seront agrégés [12, 37].

1.3.4.3 Avantages et inconvénients

Les principaux avantages des modèles hybrides sont présentés dans les points suivants [1, 7, 14] :

- **Meilleure précision** : Pronostics plus précis avec un niveau de confiance élevé lorsque les modes de défaillance, le comportement de la dégradation et la propagation des défauts sont mieux capturés ;
- **Avantages de l'intégration** : Considération des avantages des modèles combinés, notamment la signification physique, le traitement des données numérique et le raisonnement humain ;
- **Éviter les faiblesses** : Viser à éviter les inconvénients des modèles concurrents, en simplifiant la modélisation physique de la méthode basée sur un modèle physique, couvrant la non-lisibilité de l'approche basée sur les données et surmontant la difficulté de traiter directement des données continues de la méthode basée sur la connaissance ;

Malgré les avantages obtenus par l'adoption de méthodes hybrides, des difficultés importantes sont perçues et sont indiquées dans ce qui suit [12, 37] :

- **Complexité de la modélisation** : Dans certains cas, il est difficile d'intégrer une méthode de pronostic avec une autre qui ne partage pas la même architecture ou qui possède des données et des informations hétérogènes ;
- **Explosion des calculs** : La fusion de différents modèles de pronostic peut nécessiter des calculs et des simulations plus poussés ;

- **Inconvénients supplémentaires :** Des défis supplémentaires sont rencontrés pour surmonter les inconvénients potentiels des techniques de pronostic combinées ;

1.3.4.4 Techniques

Dans cette section, nous discutons des modèles hybrides populaires et des techniques utilisées pour la fusion et l'agrégation de modèles de pronostic.

a. Réseau de neurones hybride

Le RNA est la technique la plus utilisée dans le domaine du pronostic pour construire des modèles hybrides vigilants en raison de leur succès dans de nombreux domaines. L'introduction d'un RNA en combinaison avec d'autres approches de pronostic vise à inclure une certaine autonomie et intelligence dans le modèle hybride développé [37]. Le modèle RNA est inclus avec succès dans les méthodes basées sur la connaissance telles que les modèles flous et les SEs, ce qui a donné lieu au développement de RNA flous et de SE connexionnistes [14, 103].

b. Modèles hybrides d'apprentissage profond

Les méthodes d'apprentissage profond ont gagné une grande importance au cours des dernières années en raison de leur capacité à analyser d'énormes quantités de données numériques sans besoin explicite d'extraction de caractéristiques. Le développement de modèles hybrides d'apprentissage profond s'augmente de jour en jour et attire l'attention des chercheurs et des praticiens pour développer des modèles offrant une meilleure précision de pronostic. De nombreuses architectures hybrides ont été développées sur la base des modèles standards connus ou à partir des modèles existants, par exemple : CNN, RNN, CNN-LSTM, CBLSTM, etc.

c. Fusion des sorties de modèles

Dans ce type d'hybridation, plusieurs modèles de pronostic sont utilisés simultanément pour prédire la durée de vie utile restante. Les résultats obtenus sont fusionnés à l'aide d'une technique d'agrégation bien élaborée pour fournir une durée de vie utile finale précise. La fusion de modèles de pronostic peut conduire à une meilleure performance dans les résultats de prédiction et fournir une meilleure précision par rapport aux méthodes simples [12]. Dans les lignes suivantes, nous présentons certaines méthodes d'agrégation adoptées dans le domaine du pronostic.

- **Moyenne pondérée**

La manière standard de calculer une solution finale des RULs obtenus à partir de méthodes de pronostic combinées est la technique de moyenne pondérée où la moyenne simple qui est un modèle de moyenne pondérée avec des poids égaux.

- **Opérateur de la moyenne pondérée ordonnée induits– Induced Ordered Weighted Averaging (IOWA)**

Cet opérateur est considéré comme une technique de calcul de moyenne pondérée développée par Yager [104]. Yager a introduit un nouveau mécanisme rendant la méthode OWA non linéaire qui est l'étape de classement où les arguments

sont classés par leurs valeurs. Au lieu d'un argument spécifique, les poids dans OWA sont affectés à une position particulière dans le classement. Yager améliore la méthode proposée à une nouvelle version appelée Induced Ordered Weighted Averaging (IOWA) par l'introduction d'un facteur auxiliaire pour classer les arguments [105]. L'étape de réorganisation constitue le nouveau aspect où depuis sa proposition, de nombreuses variantes ont été suggérées pour l'agrégation [106-108].

- **Techniques d'IA**

Plusieurs méthodes d'IA telles que l'optimisation par essaims de particules (PSO) et la programmation génétique ont été adoptées pour fusionner les différents résultats fournis par les modèles combinés. Ces techniques sont introduites pour estimer le poids optimal alloué à chacun des modèles concurrents, en résolvant une programmation linéaire soumise à certaines contraintes ou en optimisant certains critères à base d'erreurs [109].

Le tableau 1.4 souligne certaines applications de modèles hybrides et leurs exigences essentielles. Nous avons collectés dans ce tableau plusieurs références relatives à ce type d'approches de pronostic, ce qui est sans doute utile pour le développement des approche hybrides.

TABLE 1.4 – Quelques applications courantes des modèles hybrides

Classe d'approche hybride	Exigences	Techniques	Références
Multiple approches basé sur un modèle physique	Modèle physique Compréhension du mécanisme de défaillance Données historiques (utiles)	BS-SRCKF	[110]
		Gear physical models	[111]
Multiple approches guidées par les données	Historique de données Compétences en IA, statistiques et probabilités	EWMA + SVR + RFR + DE	[112]
		Multiple GPR	[113]
		CNN-LSTM	[114, 115]
		CNN-SBULSTM	[116]
		ADLSTM-MC	[117]
		LSTM + GPR	[118]
		IDMFFN	[119]
DTMLKR	[120]		
Multiples modèles à base de connaissances	Données d'expérience Compétences en IA	CBR + RBR	[121]
		Fuzzy expert system	[122]
Modèle basé sur un modèle physique avec modèle guidé par les données	Modèle physique Compréhension du mécanisme de défaillance Historique de données Compétences en IA, statistiques et probabilités	AUKF-GA-SVR	[123]
		PSW + modified Paris crack growth model	[124]
		DNN +physics-inferred model	[125]
Modèle basé sur un modèle physique avec modèle basé sur la connaissance	Modèle physique Compréhension du mécanisme de défaillance Données d'expérience Compétences en IA	Kalman filter + Fuzzy logic and expert human knowledge	[126]
Modèle guidé par les données et modèle basé sur les connaissances	Historique de données Compétences en IA, statistiques et probabilités Données d'expérience Compétences en IA	HMM + BRB (Expert system)	[127]
		MoG-EHMM	[128]
Modèle basé sur la physique avec un modèle basé sur les données et un modèle basé sur la connaissance	Modèle physique Compréhension du mécanisme de défaillance Historique de données Compétences en IA, statistiques et probabilités Données d'expérience Compétences en IA	FB+DD+KB	[129]

1.4 Applications de pronostic

Cette section donne un bref aperçu de certaines applications de pronostic, soit dans des domaines généraux ou des composants spécifiques.

1.4.1 Domaines d'application

Dans ce qui suit, certains domaines d'application générale des procédures PHM sont élucidés.

a. Génie mécanique

Une grande variété de produits mécaniques est utilisé comme composant critique dans différents systèmes, notamment les véhicules et les machines industrielles. Par conséquent, le pronostic, la sécurité et la fiabilité de ces produits mécaniques sont devenus des préoccupations essentielles dans le monde entier. Pour ce faire, différentes approches sont proposées et adoptées par les chercheurs pour la prédiction de la durée de vie utile de ces systèmes [130].

b. Electronique

Dans un système industriel complexe, les composants électroniques sont largement implémentés et utilisés pour assurer le fonctionnement du système. Ces composants sont considérés comme des éléments critiques car une défaillance peut engendrer des défauts catastrophiques ou altérer le fonctionnement du système. Par conséquent, la surveillance de ces composants et le développement d'outils de diagnostic et de pronostic fiables qui contrôlent leur état et prédisent la durée de vie restante appropriée constituent le principal défi [11].

c. Éoliennes

Ces dernières années, l'application de l'énergie éolienne se développe de jour en jour dans le monde. En général, les éoliennes sont plus grandes en taille et en puissance et sont installées dans des grandes fermes, ce qui signifie qu'elles fonctionnent dans des conditions environnementales différentes et complexes. Par conséquent, la gestion du pronostic et de l'état des éoliennes est une procédure très importante pour assurer un fonctionnement fiable et efficace des parcs éoliens et maintenir la quantité d'énergie fournie [131].

Nous n'avons mentionné dans la dernière section que quelques domaines d'application des méthodes PHM, alors que plusieurs autres disciplines introduisent des solutions PHM dans leurs systèmes, notamment les véhicules, les systèmes énergétiques, le domaine avio-nique, les systèmes aérospatiaux et bien d'autres

1.4.2 Applications focalisées sur des composants

Dans les systèmes de fabrication, certains composants sont considérés comme des éléments critiques pour lesquels leur surveillance est très importante [7, 132]. Dans ce qui suit, certains composants largement étudiés dans la littérature sont décrits.

a. Batteries

La batterie est le composant le plus critique du stockage d'énergie introduit dans plusieurs systèmes. Avec le développement rapide de ces systèmes, la fabrication des batteries est augmentée ces dernières années et a reçu plus d'exigence pour sa gestion et son contrôle périodique [133]. Pour ce faire, le développement des modèles puissants pour estimer l'état des batteries à une importance auprès des chercheurs et des industriels. De nombreux articles de synthèse ont été publiés dans plusieurs revues afin d'aborder les techniques adoptées pour le pronostic de l'état de batterie (SoH) et la prédiction du RUL [38, 134-136].

b. Engrenages

Les engrenages sont des composants critiques dans les machines tournantes dans lesquelles leur surveillance et leur entretien sont d'une grande importance par les ingénieurs chercheurs et les praticiens industriels [137]. D'après les directives de la norme ISO 10825 :1995, les défauts des engrenages sont classés en cinq groupes : fissure, fatigue, éraflure, rupture de dent et déformation permanente. L'un des défis principaux du pronostic des engrenages et des roulements est l'identification d'un indicateur d'état direct et simple comme dans le cas des batteries [138]. Plusieurs travaux traitant le diagnostic et le pronostic des engrenages en plus de la construction de leur indicateur d'état sont présentés dans la littérature [15, 137, 138].

c. Roulements

Les roulements sont d'autres composants critiques utilisés dans les machines tournantes où leurs défauts provoquent une dégradation croissante dans les éléments adjacents et l'ensemble du système. Par conséquent, la surveillance de l'état des roulements est inévitable pour garantir la fiabilité et la sécurité de fonctionnement des composants adjacents et préserver la fonction générale du système [138]. Les causes principales de défaillance des roulements sont classées en trois origines : erreurs d'assemblage, qualité du lubrifiant et les conditions de fonctionnement [15]. Le pronostic d'état des roulements a été considéré par plusieurs travaux de synthèse dans la littérature [132, 138, 139] et un modèle hybride est adopté dans le travail de Wang et al [112]. Sim et al ont établi un tutoriel sur la manière d'extraire des caractéristiques pertinentes à des fins de pronostic des engrenages et des roulements [140].

D'autres composants critiques ont une importance pour leur surveillance et leur pronostic, comme les axes de rotation, les diodes, les alternateurs, les pompes et bien d'autres [14, 132].

1.5 Jeux de données

L'ingrédient critique de la procédure de pronostic est la disponibilité des données historiques reflétant le comportement de dégradation du système étudié. En réalité, il est difficile de trouver un ensemble de données représentatives obtenues à partir de systèmes réels en

raison de différents obstacles. La longue durée de vie du processus de dégradation, les accidents catastrophiques et soudains, les événements externes et les conditions environnementales ainsi que la confiance et la concurrence commerciale sont quelques causes critiques de la présence de ce type de données à usage public [4]. Le mécanisme de dégradation accélérée est l'une des stratégies largement utilisées pour contourner ces problèmes et fournir des jeux de données dans une petite période. Dans les lignes suivantes, nous fournissons quelques ensembles de données populaires adoptés dans le domaine de PHM. Il convient de mentionner que plusieurs jeux de données sont fournis sur le site Web de NASA Prognostics Center of excellence [141].

a. Jeux de données de simulation de dégradation de turboréacteurs

En utilisant le Commercial Modular Aero Propulsion System Simulation C-MAPSS développé par la NASA, des données de simulation de fonctionnement de turboréacteurs sont fournies pour un usage public. Un total de 21 sorties sélectionnées parmi 58 séries temporelles générées par le simulateur sont fournies à des fins de pronostic. Quatre ensembles de données ont été générés dans différentes conditions et l'un d'entre eux a été sélectionné pour la conférence de compétition PHM'08 [142]. Plus de détails sur les données et leurs applications sont fournis dans les travaux de Saxena et al. [143] et Lei et al. [4] en plus de site web de NASA[141].

b. Jeu de données IMS des roulements

Un jeu de données sur les essais de défaillances de roulements est fourni par le centre NSF I/UCR pour les systèmes de maintenance intelligents. Trois jeux de données sur quatre roulements installés sur un arbre où des accéléromètres sont montés dans ces roulements. Deux accéléromètres sont installés dans chaque roulement pour la première base et un seul pour chaque roulement pour les deux derniers jeux de données. Plus de détails sur les jeux de données et leurs applications sont fournis sur le site web de NASA [141] et le travail de Lei et al [4]. Un exemple d'une méthode hybride a été proposé pour ce jeu de données par Ahmad et al [144].

c. Jeu de données des fraiseuses

Seize cas de données "run-to-failure" sont collectés à partir d'expériences réalisées sur une fraiseuse avec différentes conditions de fonctionnement. Les données sont collectées à partir de différents types de capteurs installés dans la machine. Diverses valeurs de profondeur et de vitesses de coupe avec deux types de matériaux ont été adoptées dans cette expérience pour étudier une variété de tests [145]. Les données ont été présenté en détail avec des travaux associés sur le site web de NASA [141] et dans l'article de Lei et al [4].

d. Jeu de données de roulements FEMTO (IEEE PHM 2012 Prognostic challenge)

Un jeu de données sur les roulements est fourni par l'IEEE Reliability Society et l'institut FEMTO-ST dans le cadre du compétition IEEE PHM 2012. Une dégradation accélérée des roulements est effectuée sur une plateforme expérimentale de laboratoire PRONOSTIA dans différentes conditions de fonctionnement dans lesquelles certaines données numériques sont enregistrées. Six ensembles de données « run-to failure »

sont fournis aux participants pour développer leur propre méthode de pronostic dans laquelle 11 autres sont pris en compte pour l'estimation du RUL [146]. Plus de détails sur les données et leurs applications sont présentés dans la dernière référence et le site web du NASA [141] et dans le travail de Lei et al [4].

D'autres jeux de données publiques sont disponibles dans la littérature et sur certains sites web pour fournir des données précieuses aux chercheurs et aux industriels afin que les approches de pronostic qu'ils proposent puissent être testées et validées [43]. Pour les jeux de données disponibles sur les batteries, le lecteur intéressé peut se référer à l'article de Hasib et al [147].

1.6 Conclusion

Dans ce chapitre, nous avons présenté en détail les principaux concepts et définitions du pronostic, à savoir la surveillance, l'indicateur d'état et la durée de vie utile restante. Les quatre principales catégories d'approches de pronostic sont discutées en détail, y compris l'approche basée sur un modèle physique qui nécessite comme ingrédient essentiel le modèle physique du processus. Les approches guidées par les données et les méthodes basées sur les connaissances sont d'autres visions qui considèrent comme un apport important les données numériques historiques et les informations des experts respectivement. Dans ce chapitre, nous nous sommes concentrés sur les approches hybrides, qui constituent la quatrième catégorie d'approches de pronostic et visent à combiner plusieurs techniques classiques afin de bénéficier des avantages inhérents et de surmonter les limites de leur utilisation individuelle. En outre, nous avons fourni les configurations possibles des solutions hybrides et les stratégies potentielles qui peuvent être adoptées pour des applications réelles. Les catégories principales, les avantages et les limites des techniques susmentionnées ont été présentées et discutées afin de donner un meilleur aperçu de leur adoption. Pour une aide pratique, nous avons introduit pour chaque approche des techniques populaires adoptées dans la littérature. Par exemple, le filtre à particules, le RNA, le système expert et le réseau neuronal hybride sont des modèles largement utilisés dans le domaine du PHM pour les techniques basées sur le modèle physique, les données, les connaissances et les techniques hybrides, respectivement. Après avoir détaillé les différentes techniques adoptées, nous avons présenté les applications principales de ces méthodes, que ce soit dans des domaines généraux comme la mécanique ou dans des composants spécifiques comme les batteries. Avant de conclure le chapitre, nous avons spécifié quelques jeux de données populaires et largement utilisés qui peuvent être appliqués pour évaluer l'efficacité d'une technique proposée.

Dans les prochains chapitres, nous nous concentrerons sur le développement et la validation de modèles hybrides pour estimer la durée de vie restante des équipements industriels, en choisissant les batteries comme exemple d'application.

Références

1. XIA, T. *et al.* Recent advances in prognostics and health management for advanced manufacturing paradigms. *Reliability Engineering & System Safety* **178**, 255-268. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S095183201731459X> (1^{er} oct. 2018).
2. KIM, N.-H., AN, D. & CHOI, J.-H. in *Prognostics and Health Management of Engineering Systems* 1-24 (Springer, Cham, 2017). ISBN : 978-3-319-44740-7 978-3-319-44742-1.
3. VACHTSEVANOS, G., LEWIS, F., MICHAEL, R., HESS, A. & WU, F. *Intelligent Fault Diagnosis and Prognosis for Engineering Systems - George Vachtsevanos, Frank L. Lewis, Michael Roemer, et al* JOHN WILEY & SONS, INC. <http://www.wiley.com/WileyCDA/WileyTitle/productCd-047172999X.html> (2006).
4. LEI, Y. *et al.* Machinery health prognostics : A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing* **104**, 799-834. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327017305988> (1^{er} mai 2018).
5. GUO, J., LI, Z. & LI, M. A Review on Prognostics Methods for Engineering Systems. *IEEE Transactions on Reliability* **69**. Number : 3 Conference Name : IEEE Transactions on Reliability, 1110-1129. ISSN : 1558-1721 (sept. 2020).
6. SIKORSKA, J. Z., HODKIEWICZ, M. & MA, L. Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing* **25**, 1803-1836. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327010004218> (1^{er} juill. 2011).
7. BAUR, M., ALBERTELLI, P. & MONNO, M. A review of prognostics and health management of machine tools. *The International Journal of Advanced Manufacturing Technology* **107**. Number : 5, 2843-2863. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-020-05202-3> (1^{er} mars 2020).
8. MOSALLAM, A., MEDJAHAR, K. & ZERHOUNI, N. *Component based data-driven prognostics for complex systems : Methodology and applications* in 2015 First International Conference on Reliability Systems Engineering (ICRSE) 2015 First International Conference on Reliability Systems Engineering (ICRSE) (oct. 2015), 1-7.
9. AHMADZADEH, F. & LUNDBERG, J. Remaining useful life estimation : review. *International Journal of System Assurance Engineering and Management* **5**, 461-474. ISSN : 0975-6809, 0976-4348. <https://link.springer.com/article/10.1007/s13198-013-0195-0> (1^{er} déc. 2014).
10. BJAILI, H. A. & RUSHDI, A. M. Prognostics and Health Monitoring Methodologies and Approaches : A Review. *Journal of Engineering Research and Reports*, 30-50. ISSN : 2582-2926. <https://journaljerr.com/index.php/JERR/article/view/17215> (18 nov. 2020).
11. ELATTAR, H. M., ELMINIR, H. K. & RIAD, A. M. Prognostics : a literature review. *Complex & Intelligent Systems* **2**, 125-154. ISSN : 2199-4536, 2198-6053. <https://link.springer.com/article/10.1007/s40747-016-0019-3> (1^{er} juin 2016).
12. LIAO, L. & KÖTTIG, F. 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**, 191-207. ISSN : 0018-9529 (mars 2014).

13. WELTE, T. M. & WANG, K. Models for lifetime estimation : an overview with focus on applications to wind turbines. *Advances in Manufacturing* **2**, 79-87. ISSN : 2095-3127, 2195-3597. <https://link.springer.com/article/10.1007/s40436-014-0064-3> (1^{er} mars 2014).
14. PENG, Y., DONG, M. & ZUO, M. J. Current status of machine prognostics in condition-based maintenance : a review. *The International Journal of Advanced Manufacturing Technology* **50**, 297-313. ISSN : 0268-3768, 1433-3015. <https://link.springer.com/article/10.1007/s00170-009-2482-0> (1^{er} sept. 2010).
15. CUBILLO, A., PERINPANAYAGAM, S. & ESPERON-MIGUEZ, M. A review of physics-based models in prognostics : Application to gears and bearings of rotating machinery. *Advances in Mechanical Engineering* **8**. Number : 8 Publisher : SAGE Publications, 1687814016664660. ISSN : 1687-8140. <https://doi.org/10.1177/1687814016664660> (1^{er} août 2016).
16. WANG, Y., ZHAO, Y. & ADDEPALLI, S. Remaining Useful Life Prediction using Deep Learning Approaches : A Review. *Procedia Manufacturing. Proceedings of the 8th International Conference on Through-Life Engineering Services – TESConf 2019* **49**, 81-88. ISSN : 2351-9789. <http://www.sciencedirect.com/science/article/pii/S2351978920316528> (1^{er} jan. 2020).
17. AN, D., KIM, N. H. & CHOI, J.-H. Practical options for selecting data-driven or physics-based prognostics algorithms with reviews. *Reliability Engineering & System Safety* **133**, 223-236. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S0951832014002245> (Supplement C 1^{er} jan. 2015).
18. ATAMURADOV, V., MEDJAHER, K., DERSIN, P., LAMOUREUX, B. & ZERHOUNI, N. Prognostics and health management for maintenance practitioners - Review, implementation and tools evaluation. *International Journal of Prognostics and Health Management* **8**. Number : 060 Publisher : PHM Society, 1-31. ISSN : 2153-2648. <https://www.phmsociety.org/node/2246> (11 déc. 2017).
19. AN, D., CHOI, J.-H. & KIM, N. H. Prognostics 101 : A tutorial for particle filter-based prognostics algorithm using Matlab. *Reliability Engineering & System Safety* **115**, 161-169. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832013000549> (1^{er} juill. 2013).
20. KAN, M. S., TAN, A. C. & MATHEW, J. A review on prognostic techniques for non-stationary and non-linear rotating systems. *Mechanical Systems and Signal Processing* **62-63**, 1-20. ISSN : 08883270. <https://linkinghub.elsevier.com/retrieve/pii/S0888327015000898> (oct. 2015).
21. GRAY, C. S. & WATSON, S. J. Physics of Failure approach to wind turbine condition based maintenance. *Wind Energy* **13**, 395-405. ISSN : 1099-1824. <http://onlinelibrary.wiley.com/doi/abs/10.1002/we.360> (2010).
22. STRINGER, D. B., SHETH, P. N. & ALLAIRE, P. E. Physics-based modeling strategies for diagnostic and prognostic application in aerospace systems. *Journal of Intelligent Manufacturing* **23**, 155-162. ISSN : 1572-8145. <https://doi.org/10.1007/s10845-009-0340-4> (1^{er} avr. 2012).
23. WANG, H., SONG, W., ZIO, E., KUDREYKO, A. & ZHANG, Y. Remaining useful life prediction for Lithium-ion batteries using fractional Brownian motion and Fruit-fly Optimization Algorithm. *Measurement* **161**, 107904. ISSN : 0263-2241. <https://www.sciencedirect.com/science/article/pii/S0263224120304425> (1^{er} sept. 2020).

24. JIAO, R., PENG, K., DONG, J. & ZHANG, C. Fault monitoring and remaining useful life prediction framework for multiple fault modes in prognostics. *Reliability Engineering & System Safety* **203**, 107028. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832020305299> (1^{er} nov. 2020).
25. LIU, X., SONG, P., YANG, C., HAO, C. & PENG, W. Prognostics and Health Management of Bearings Based on Logarithmic Linear Recursive Least-Squares and Recursive Maximum Likelihood Estimation. *IEEE Transactions on Industrial Electronics* **PP**, 1-1. ISSN : 0278-0046 (2017).
26. TAGADE, P. *et al.* Recursive Bayesian filtering framework for lithium-ion cell state estimation. *Journal of Power Sources* **306**, 274-288. ISSN : 0378-7753. <http://www.sciencedirect.com/science/article/pii/S0378775315306273> (Supplement C 29 fév. 2016).
27. JOUIN, M., GOURIVEAU, R., HISSEL, D., PÉRA, M.-C. & ZERHOUNI, N. Particle filter-based prognostics : Review, discussion and perspectives. *Mechanical Systems and Signal Processing* **72-73**, 2-31. ISSN : 0888-3270. <https://www.sciencedirect.com/science/article/pii/S088832701500504X> (1^{er} mai 2016).
28. SINGLETON, R. K., STRANGAS, E. G. & AVIYENTE, S. Extended Kalman Filtering for Remaining-Useful-Life Estimation of Bearings. *IEEE Transactions on Industrial Electronics* **62**, 1781-1790. ISSN : 0278-0046 (mars 2015).
29. YANG, X. & MACIEJOWSKI, J. M. Fault-tolerant model predictive control of a wind turbine benchmark. *IFAC Proceedings Volumes* **45**, 337-342. ISSN : 1474-6670. <http://www.sciencedirect.com/science/article/pii/S1474667016347772> (1^{er} jan. 2012).
30. LIM, C. K. R. & MBA, D. Switching Kalman filter for failure prognostic. *Mechanical Systems and Signal Processing* **52-53**, 426-435. ISSN : 0888-3270. <https://www.sciencedirect.com/science/article/pii/S0888327014003227> (1^{er} fév. 2015).
31. LALL, P., LOWE, R. & GOEBEL, K. Prognostics Health Management of Electronic Systems Under Mechanical Shock and Vibration Using Kalman Filter Models and Metrics. *IEEE Transactions on Industrial Electronics* **59**. Conference Name : IEEE Transactions on Industrial Electronics, 4301-4314. ISSN : 1557-9948 (nov. 2012).
32. DUAN, B., ZHANG, Q., GENG, F. & ZHANG, C. Remaining useful life prediction of lithium-ion battery based on extended Kalman particle filter. *International Journal of Energy Research* **44**, 1724-1734. ISSN : 1099-114X. <https://onlinelibrary.wiley.com/doi/abs/10.1002/er.5002> (2020).
33. BECHHOEFER, E., BERNHARD, A. & HE, D. *Use of Paris Law for Prediction of Component Remaining Life in 2008 IEEE Aerospace Conference 2008* IEEE Aerospace Conference. ISSN : 1095-323X (mars 2008), 1-9.
34. CORBETTA, M., SBARUFATTI, C., MANES, A. & GIGLIO, M. Real-Time Prognosis of Crack Growth Evolution Using Sequential Monte Carlo Methods and Statistical Model Parameters. *IEEE Transactions on Reliability* **64**. Conference Name : IEEE Transactions on Reliability, 736-753. ISSN : 1558-1721 (juin 2015).
35. LI, Y. *et al.* Adaptive prognostics for rolling element bearing condition. *Mechanical Systems and Signal Processing* **13**, 103-113. ISSN : 0888-3270. <https://www.sciencedirect.com/science/article/pii/S0888327098901832> (1^{er} jan. 1999).
36. SI, X.-S., ZHANG, Z.-X. & HU, C.-H. *Data-Driven Remaining Useful Life Prognosis Techniques* ISBN : 978-3-662-54028-2 978-3-662-54030-5. <http://link.springer.com/10.1007/978-3-662-54030-5> (Springer Berlin Heidelberg, Berlin, Heidelberg, 2017).

37. MONTERO-JIMENEZ, J. J., SCHWARTZ, S., VINGERHOEDS, R., GRABOT, B. & SALAÜN, M. Towards multi-model approaches to predictive maintenance : A systematic literature survey on diagnostics and prognostics. *Journal of Manufacturing Systems* **56**, 539-557. ISSN : 0278-6125. <http://www.sciencedirect.com/science/article/pii/S0278612520301187> (1^{er} juill. 2020).
38. WU, L., FU, X. & GUAN, Y. Review of the Remaining Useful Life Prognostics of Vehicle Lithium-Ion Batteries Using Data-Driven Methodologies. *Applied Sciences* **6**, 166. <http://www.mdpi.com/2076-3417/6/6/166> (27 mai 2016).
39. SUTHARSSAN, T., STOYANOV, S., BAILEY, C. & YIN, C. Prognostic and health management for engineering systems : a review of the data-driven approach and algorithms. *The Journal of Engineering* **2015**, 215-222. ISSN : 2051-3305. <http://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/joe.2014.0303> (2015).
40. SI, X.-S., WANG, W., HU, C.-H. & ZHOU, D.-H. Remaining useful life estimation – A review on the statistical data driven approaches. *European Journal of Operational Research* **213**, 1-14. ISSN : 0377-2217. <http://www.sciencedirect.com/science/article/pii/S0377221710007903> (16 août 2011).
41. TAHERI, E., KOLMANOVSKY, I. & GUSIKHIN, O. Survey of prognostics methods for condition-based maintenance in engineering systems. *arXiv:1912.02708 [cs, eess]*. arXiv : [1912.02708](http://arxiv.org/abs/1912.02708). <http://arxiv.org/abs/1912.02708> (2 déc. 2019).
42. THOPPIL, N. M., VASU, V. & RAO, C. S. P. Deep Learning Algorithms for Machinery Health Prognostics Using Time-Series Data : A Review. *Journal of Vibration Engineering & Technologies*. ISSN : 2523-3939. <https://doi.org/10.1007/s42417-021-00286-x> (1^{er} mars 2021).
43. REZAEIANJOUYBARI, B. & SHANG, Y. Deep learning for prognostics and health management : State of the art, challenges, and opportunities. *Measurement* **163**, 107929. ISSN : 0263-2241. <https://www.sciencedirect.com/science/article/pii/S026322412030467X> (15 oct. 2020).
44. GORJIAN, N., MA, L., MITTINTY, M., YARLAGADDA, P. & SUN, Y. in *Engineering Asset Lifecycle Management* 369-384 (Springer, London, 2010). ISBN : 978-0-85729-321-3 978-0-85729-320-6. https://link.springer.com/chapter/10.1007/978-0-85729-320-6_42.
45. RASMUSSEN, C. E. & WILLIAMS, C. K. I. *Gaussian Processes for Machine Learning* <http://www.gaussianprocess.org/gpml/chapters/RW.pdf> (The MIT Press Cambridge MA, 2006).
46. ALASWAD, S. & XIANG, Y. A review on condition-based maintenance optimization models for stochastically deteriorating system. *Reliability Engineering & System Safety* **157**, 54-63. ISSN : 09518320. <https://linkinghub.elsevier.com/retrieve/pii/S0951832016303714> (jan. 2017).
47. ZHANG, Z., SI, X., HU, C. & LEI, Y. Degradation data analysis and remaining useful life estimation : A review on Wiener-process-based methods. *European Journal of Operational Research* **271**. Number : 3, 775-796. ISSN : 0377-2217. <https://www.sciencedirect.com/science/article/pii/S0377221718301486> (16 déc. 2018).
48. ZHANG, L. *et al.* A Review on Deep Learning Applications in Prognostics and Health Management. *IEEE Access* **7**. Conference Name : IEEE Access, 162415-162438. ISSN : 2169-3536 (2019).

49. TIAN, Z. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring. *Journal of Intelligent Manufacturing* **23**. Num Pages : 227-237 Place : London, Netherlands Publisher : Springer Nature B.V., 227-237. ISSN : 09565515. <https://www.proquest.com/docview/1112162152/abstract/45FA4CE219B64FD7PQ/1> (2012).
50. GEBRAEEL, N. Z. & LAWLEY, M. A. A Neural Network Degradation Model for Computing and Updating Residual Life Distributions. *IEEE Transactions on Automation Science and Engineering* **5**. Conference Name : IEEE Transactions on Automation Science and Engineering, 154-163. ISSN : 1558-3783 (jan. 2008).
51. TIAN, Z. & ZUO, M. J. Health Condition Prediction of Gears Using a Recurrent Neural Network Approach. *IEEE Transactions on Reliability* **59**. Conference Name : IEEE Transactions on Reliability, 700-705. ISSN : 1558-1721 (déc. 2010).
52. XIAO, L., CHEN, X., ZHANG, X. & LIU, M. A novel approach for bearing remaining useful life estimation under neither failure nor suspension histories condition. *Journal of Intelligent Manufacturing* **28**, 1893-1914. ISSN : 1572-8145. <https://doi.org/10.1007/s10845-015-1077-x> (1^{er} déc. 2017).
53. ZHAO, Z., BIN LIANG, WANG, X. & LU, W. Remaining useful life prediction of aircraft engine based on degradation pattern learning. *Reliability Engineering & System Safety* **164**, 74-83. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832017302454> (1^{er} août 2017).
54. YANG, D., ZHANG, X., PAN, R., WANG, Y. & CHEN, Z. A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve. *Journal of Power Sources* **384**, 387-395. ISSN : 0378-7753. <http://www.sciencedirect.com/science/article/pii/S0378775318302398> (30 avr. 2018).
55. DUONG, P. L. T., PARK, H. & RAGHAVAN, N. Application of multi-output Gaussian process regression for remaining useful life prediction of light emitting diodes. *Microelectronics Reliability. 29th European Symposium on Reliability of Electron Devices, Failure Physics and Analysis (ESREF 2018)* **88-90**, 80-84. ISSN : 0026-2714. <http://www.sciencedirect.com/science/article/pii/S0026271418306723> (1^{er} sept. 2018).
56. RICHARDSON, R. R., OSBORNE, M. A. & HOWEY, D. A. Gaussian process regression for forecasting battery state of health. *Journal of Power Sources* **357**, 209-219. ISSN : 0378-7753. <http://www.sciencedirect.com/science/article/pii/S0378775317306250> (Supplement C 31 juill. 2017).
57. BARALDI, P., MANGILI, F. & ZIO, E. A prognostics approach to nuclear component degradation modeling based on Gaussian Process Regression. *Progress in Nuclear Energy* **78**, 141-154. ISSN : 0149-1970. <http://www.sciencedirect.com/science/article/pii/S0149197014002431> (Supplement C 1^{er} jan. 2015).
58. BENKEDJOUH, T., MEDJAHAR, K., ZERHOUNI, N. & RECHAK, S. Health assessment and life prediction of cutting tools based on support vector regression. *Journal of Intelligent Manufacturing* **26**, 213-223. ISSN : 0956-5515, 1572-8145. <https://link.springer.com/article/10.1007/s10845-013-0774-6> (1^{er} avr. 2015).
59. NUHIC, A., TERZIMEHIC, T., SOCZKA-GUTH, T., BUCHHOLZ, M. & DIETMAYER, K. Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods. *Journal of Power Sources* **239**, 680-688. ISSN : 0378-7753. <http://www.sciencedirect.com/science/article/pii/S0378775312018605> (Supplement C 1^{er} oct. 2013).

60. BENKEDJOUH, T., MEDJAHAR, K., ZERHOUNI, N. & RECHAK, S. Remaining useful life estimation based on nonlinear feature reduction and support vector regression. *Engineering Applications of Artificial Intelligence* **26**, 1751-1760. ISSN : 0952-1976. <http://www.sciencedirect.com/science/article/pii/S0952197613000365> (1^{er} août 2013).
61. XIAO, Y., WANG, H., XU, W. & ZHOU, J. Robust one-class SVM for fault detection. *Chemometrics and Intelligent Laboratory Systems* **151**, 15-25. ISSN : 0169-7439. <https://www.sciencedirect.com/science/article/pii/S0169743915003056> (15 fév. 2016).
62. DUAN, C., DENG, C. & LI, N. Reliability assessment for CNC equipment based on degradation data. *The International Journal of Advanced Manufacturing Technology* **100**, 421-434. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-018-2548-y> (1^{er} jan. 2019).
63. HUANG, H.-z., WANG, H.-k., LI, Y.-f., ZHANG, L. & LIU, Z. Support vector machine based estimation of remaining useful life : current research status and future trends. *Journal of Mechanical Science and Technology* **29**. Num Pages : 151-163 Place : Heidelberg, Netherlands Publisher : Springer Nature B.V., 151-163. ISSN : 1738494X. <https://www.proquest.com/docview/1645536323/abstract/D1E2E1E4677348AEPQ/1> (2015).
64. WIDODO, A. & YANG, B.-S. Machine health prognostics using survival probability and support vector machine. *Expert Systems with Applications* **38**, 8430-8437. ISSN : 0957-4174. <https://www.sciencedirect.com/science/article/pii/S0957417411000583> (1^{er} juill. 2011).
65. LU, C., CHEN, J., HONG, R., FENG, Y. & LI, Y. Degradation trend estimation of slewing bearing based on LSSVM model. *Mechanical Systems and Signal Processing* **76-77**, 353-366. ISSN : 0888-3270. <https://www.sciencedirect.com/science/article/pii/S0888327016000820> (1^{er} août 2016).
66. BERECIBAR, M. *et al.* Online state of health estimation on NMC cells based on predictive analytics. *Journal of Power Sources* **320**, 239-250. ISSN : 0378-7753. <https://www.sciencedirect.com/science/article/pii/S0378775316304827> (15 juill. 2016).
67. PAN, Z., MENG, Z., CHEN, Z., GAO, W. & SHI, Y. A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings. *Mechanical Systems and Signal Processing* **144**, 106899. ISSN : 0888-3270. <https://www.sciencedirect.com/science/article/pii/S0888327020302855> (1^{er} oct. 2020).
68. LI, X., DING, Q. & SUN, J.-Q. Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering & System Safety* **172**, 1-11. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832017307779> (1^{er} avr. 2018).
69. MUNEEER, A., TAIB, S. M., FATI, S. M. & ALHUSSIAN, H. Deep-Learning Based Prognosis Approach for Remaining Useful Life Prediction of Turbofan Engine. *Symmetry* **13**. Number : 10 Publisher : Multidisciplinary Digital Publishing Institute, 1861. <https://www.mdpi.com/2073-8994/13/10/1861> (oct. 2021).
70. REN, L., SUN, Y., CUI, J. & ZHANG, L. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks. *Journal of Manufacturing Systems. Special Issue on Smart Manufacturing* **48**, 71-77. ISSN : 0278-6125. <https://www.sciencedirect.com/science/article/pii/S0278612518300475> (1^{er} juill. 2018).
71. ZHANG, Y., XIONG, R., HE, H. & PECHT, M. G. Long Short-Term Memory Recurrent Neural Network for Remaining Useful Life Prediction of Lithium-Ion Batteries. *IEEE Transactions on Vehicular Technology* **67**, 5695-5705. ISSN : 0018-9545 (juill. 2018).

72. LISTOU ELLEFSEN, A., BJØRLYKHAUG, E., ÆSØY, V., USHAKOV, S. & ZHANG, H. Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture. *Reliability Engineering & System Safety* **183**, 240-251. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S0951832018307506> (1^{er} mars 2019).
73. CHEN, Y., PENG, G., ZHU, Z. & LI, S. A novel deep learning method based on attention mechanism for bearing remaining useful life prediction. *Applied Soft Computing* **86**, 105919. ISSN : 1568-4946. <https://www.sciencedirect.com/science/article/pii/S1568494619307008> (1^{er} jan. 2020).
74. ZHAO, R. *et al.* Machine Health Monitoring Using Local Feature-Based Gated Recurrent Unit Networks. *IEEE Transactions on Industrial Electronics* **65**. Conference Name : IEEE Transactions on Industrial Electronics, 1539-1548. ISSN : 1557-9948 (fév. 2018).
75. FAN, Y., NOWACZYK, S. & RÖGNVALDSSON, T. Transfer learning for remaining useful life prediction based on consensus self-organizing models. *Reliability Engineering & System Safety* **203**, 107098. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832020305998> (1^{er} nov. 2020).
76. ZHOU, J.-H., PANG, C. K., ZHONG, Z.-W. & LEWIS, F. L. Tool Wear Monitoring Using Acoustic Emissions by Dominant-Feature Identification. *Transactions on instrumentation and measurement* **60**, 547-559 (2011).
77. BARRAZA-BARRAZA, D., TERCERO-GÓMEZ, V. G., BERUVIDES, M. G. & LIMÓN-ROBLES, J. An adaptive ARX model to estimate the RUL of aluminum plates based on its crack growth. *Mechanical Systems and Signal Processing* **82**, 519-536. ISSN : 0888-3270. <https://www.sciencedirect.com/science/article/pii/S0888327016301327> (1^{er} jan. 2017).
78. ESCOBET, T., QUEVEDO, J. & PUIG, V. A fault/anomaly system prognosis using a data-driven approach considering uncertainty in *The 2012 International Joint Conference on Neural Networks (IJCNN)* The 2012 International Joint Conference on Neural Networks (IJCNN). ISSN : 2161-4407 (juin 2012), 1-7.
79. HU, Y.-W., ZHANG, H.-C., LIU, S.-J. & LU, H.-T. Sequential Monte Carlo Method Toward Online RUL Assessment with Applications. *Chinese Journal of Mechanical Engineering* **31**. Number : 1 Publisher : SpringerOpen, 1-12. ISSN : 2192-8258. <https://cjme.springeropen.com/articles/10.1186/s10033-018-0205-x> (déc. 2018).
80. PAN, Z. & BALAKRISHNAN, N. Reliability modeling of degradation of products with multiple performance characteristics based on gamma processes. *Reliability Engineering & System Safety* **96**, 949-957. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832011000421> (1^{er} août 2011).
81. SHAFIEE, M., FINKELSTEIN, M. & BÉRENGUER, C. An opportunistic condition-based maintenance policy for offshore wind turbine blades subjected to degradation and environmental shocks. *Reliability Engineering & System Safety* **142**, 463-471. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832015001428> (1^{er} oct. 2015).
82. TIAN, Z. & LIAO, H. Condition based maintenance optimization for multi-component systems using proportional hazards model. *Reliability Engineering & System Safety* **96**, 581-589. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832010002796> (1^{er} mai 2011).

83. ZHANG, Q., HUA, C. & XU, G. A mixture Weibull proportional hazard model for mechanical system failure prediction utilising lifetime and monitoring data. *Mechanical Systems and Signal Processing* **43**, 103-112. ISSN : 0888-3270. <https://www.sciencedirect.com/science/article/pii/S0888327013005165> (3 fév. 2014).
84. LO, H., GHASEMI, A., DIALLO, C. & NEWHOOK, J. Comparative study on logical analysis of data (LAD), artificial neural networks (ANN), and proportional hazards model (PHM) for maintenance prognostics. *Journal of Quality in Maintenance Engineering* **25**. Num Pages : 23 Place : Bradford, United Kingdom Publisher : Emerald Group Publishing Limited, 2-24. ISSN : 13552511. <https://www.proquest.com/docview/2187587423/abstract/2F42F232D07D4FFEPQ/1> (2019).
85. SUN, H., PAN, J., ZHANG, J. & CAO, D. Non-linear Wiener process-based cutting tool remaining useful life prediction considering measurement variability. *The International Journal of Advanced Manufacturing Technology* **107**, 4493-4502. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-020-05264-3> (1^{er} avr. 2020).
86. SHEN, Y., SHEN, L. & XU, W. A Wiener-based degradation model with logistic distributed measurement errors and remaining useful life estimation. *Quality and Reliability Engineering International* **34**, 1289-1303. ISSN : 1099-1638. <https://onlinelibrary.wiley.com/doi/abs/10.1002/qre.2325> (1^{er} oct. 2018).
87. KUMAR, A., CHINNAM, R. B. & TSENG, F. An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools. *Computers & Industrial Engineering*. ISSN : 0360-8352. <http://www.sciencedirect.com/science/article/pii/S0360835218302183> (12 mai 2018).
88. CAMCI, F. & CHINNAM, R. B. Health-State Estimation and Prognostics in Machining Processes. *IEEE Transactions on Automation Science and Engineering* **7**, 581-597. ISSN : 1545-5955 (juill. 2010).
89. ZHANG, D., BAILEY, A. D. & DJURDJANOVIC, D. Bayesian Identification of Hidden Markov Models and Their Use for Condition-Based Monitoring. *IEEE Transactions on Reliability* **65**. Conference Name : IEEE Transactions on Reliability, 1471-1482. ISSN : 1558-1721 (sept. 2016).
90. GEBRAEEL, N. Z., LAWLEY, M. A., LI, R. & RYAN, J. K. Residual-life distributions from component degradation signals : A Bayesian approach. *IIE Transactions* **37**. Publisher : Taylor & Francis _eprint : <https://doi.org/10.1080/07408170590929018>, 543-557. ISSN : 0740-817X. <https://doi.org/10.1080/07408170590929018> (1^{er} juin 2005).
91. DONG, M. & YANG, Z.-b. Dynamic Bayesian network based prognosis in machining processes. *Journal of Shanghai Jiaotong University (Science)* **13**, 318-322. ISSN : 1995-8188. <https://doi.org/10.1007/s12204-008-0318-y> (1^{er} juin 2008).
92. CHEMWENO, P., PINTELON, L., JONGERS, L. & MUCHIRI, P. *i-RCAM : Intelligent expert system for root cause analysis in maintenance decision making* in 2016 IEEE International Conference on Prognostics and Health Management (ICPHM) 2016 IEEE International Conference on Prognostics and Health Management (ICPHM) (juin 2016), 1-7.
93. TANG, X., XIAO, M., LIANG, Y., ZHU, H. & LI, J. Online updating belief-rule-base using Bayesian estimation. *Knowledge-Based Systems* **171**, 93-105. ISSN : 0950-7051. <https://www.sciencedirect.com/science/article/pii/S0950705119300528> (1^{er} mai 2019).
94. POTES RUIZ, P., KAMSU FOGUEM, B. & GRABOT, B. Generating knowledge in maintenance from Experience Feedback. *Knowledge-Based Systems. Enhancing Experience Reuse and Learning* **68**, 4-20. ISSN : 0950-7051. <https://www.sciencedirect.com/science/article/pii/S0950705114000422> (1^{er} sept. 2014).

95. KUMAR, P. & SRIVASTAVA, R. *An expert system for predictive maintenance of mining excavators and its various forms in open cast mining* in 2012 1st International Conference on Recent Advances in Information Technology (RAIT) 2012 1st International Conference on Recent Advances in Information Technology (RAIT) (mars 2012), 658-661.
96. BIAGETTI, T. & SCIUBBA, E. Automatic diagnostics and prognostics of energy conversion processes via knowledge-based systems. *Energy. Efficiency, Costs, Optimization, Simulation and Environmental Impact of Energy Systems* **29**, 2553-2572. ISSN : 0360-5442. <https://www.sciencedirect.com/science/article/pii/S0360544204001082> (1^{er} oct. 2004).
97. RAMASSO, E. Investigating computational geometry for failure prognostics. *International Journal of Prognostics and Health Management* **5**. Publisher : The Prognostics and Health Management Society. ISSN : 2153-2648, 2153-2648. <https://papers.phmsociety.org/index.php/ijphm/article/view/2205> (1^{er} jan. 2014).
98. BERENJI, H. & WANG, Y. *Case-Based Reasoning for Fault Diagnosis and Prognosis* in 2006 IEEE International Conference on Fuzzy Systems 2006 IEEE International Conference on Fuzzy Systems. ISSN : 1098-7584 (juill. 2006), 1316-1321.
99. BABAN, M., BABAN, C. F. & MOISI, B. *A Fuzzy Logic-Based Approach for Predictive Maintenance of Grinding Wheels of Automated Grinding Lines* in 2018 23rd International Conference on Methods Models in Automation Robotics (MMAR) 2018 23rd International Conference on Methods Models in Automation Robotics (MMAR) (août 2018), 483-486.
100. KOTHAMASU, R. & HUANG, S. H. Adaptive Mamdani fuzzy model for condition-based maintenance. *Fuzzy Sets and Systems. Theme : Modelling and Control* **158**, 2715-2733. ISSN : 0165-0114. <https://www.sciencedirect.com/science/article/pii/S0165011407003314> (16 déc. 2007).
101. RAMEZANI, S., MOINI, A. & RIAHI, M. Prognostics and Health Management in Machinery : A Review of Methodologies for RUL prediction and Roadmap. *International Journal of Industrial Engineering and Management Science* **6**. Number : 1 Publisher : University of Hormozgan, 38-61. ISSN : 2409-1871. http://www.ijiems.com/article_86909.html (1^{er} avr. 2019).
102. JAVED, K., GOURIVEAU, R. & ZERHOUNI, N. 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. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327017300468> (Supplement C 15 sept. 2017).
103. BOUZENITA, M. *Conception et implémentation d'un système expert hybride pour le diagnostic d'un système industriel* magister (Université de Batna 2, 2012). <http://eprints.univ-batna2.dz/1036/>.
104. YAGER, R. On ordered weighted averaging aggregation operators in multicriteria decision making. *IEEE Trans. Syst., Man, Cybern* **18**, 183-190. ISSN : 0018-9472 (jan. 1988).
105. YAGER, R. & FILEV, D. P. Induced ordered weighted averaging operators. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)* **29**, 141-150. ISSN : 1083-4419 (avr. 1999).
106. YAGER, R. Families of OWA operators. *Fuzzy Sets and Systems* **59**, 125-148. ISSN : 0165-0114. <http://www.sciencedirect.com/science/article/pii/016501149390194M> (25 oct. 1993).

107. YAGER, R., KACPRZYK, J. & BELIAKOV, G. *Recent Developments in the Ordered Weighted Averaging Operators : Theory and Practice* réd. par KACPRZYK, J. ISBN : 978-3-642-17909-9 978-3-642-17910-5. <http://link.springer.com/10.1007/978-3-642-17910-5> (Springer Berlin Heidelberg, Berlin, Heidelberg, 2011).
108. VLUYMANS, S., MAC PARTHALÁIN, N., CORNELIS, C. & SAEYS, Y. Weight selection strategies for ordered weighted average based fuzzy rough sets. *Information Sciences* **501**, 155-171. ISSN : 0020-0255. <http://www.sciencedirect.com/science/article/pii/S0020025519305122> (1^{er} oct. 2019).
109. BOUZENITA, M., MOUSS, L.-H., MELGANI, F. & BENTRCIA, T. New fusion frameworks including explicit weighting functions for the remaining useful life prognostics. *Expert Systems with Applications* **189**, 116091. ISSN : 0957-4174. <https://www.sciencedirect.com/science/article/pii/S0957417421014263> (1^{er} mars 2022).
110. QIU, X., WU, W. & WANG, S. Remaining useful life prediction of lithium-ion battery based on improved cuckoo search particle filter and a novel state of charge estimation method. *Journal of Power Sources* **450**, 227700. ISSN : 0378-7753. <https://www.sciencedirect.com/science/article/pii/S0378775320300033> (29 fév. 2020).
111. ZHAO, F., TIAN, Z. & ZENG, Y. Uncertainty Quantification in Gear Remaining Useful Life Prediction Through an Integrated Prognostics Method. *IEEE Transactions on Reliability* **62**, 146-159. ISSN : 0018-9529 (mars 2013).
112. WANG, F.-K. & MAMO, T. Hybrid approach for remaining useful life prediction of ball bearings. *Quality and Reliability Engineering International* **35**. Number : 7 _eprint : <https://onlinelibrary.wiley.com/doi/pdf/10.1002/qre.2538>, 2494-2505. ISSN : 1099-1638. <http://onlinelibrary.wiley.com/doi/abs/10.1002/qre.2538> (2019).
113. LI, L., WANG, P., CHAO, K.-H., ZHOU, Y. & XIE, Y. Remaining Useful Life Prediction for Lithium-Ion Batteries Based on Gaussian Processes Mixture. *PLOS ONE* **11**, e0163004. ISSN : 1932-6203. <http://journals.plos.org/plosone/article?id=10.1371/journal.pone.0163004> (15 sept. 2016).
114. LI, X., ZHANG, L., WANG, Z. & DONG, P. Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks. *Journal of Energy Storage* **21**, 510-518. ISSN : 2352-152X. <http://www.sciencedirect.com/science/article/pii/S2352152X1830450X> (1^{er} fév. 2019).
115. ZHANG, X., LU, X., LI, W. & WANG, S. Prediction of the remaining useful life of cutting tool using the Hurst exponent and CNN-LSTM. *The International Journal of Advanced Manufacturing Technology* **112**. Number : 7, 2277-2299. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-020-06447-8> (1^{er} fév. 2021).
116. AN, Q., TAO, Z., XU, X., EL MANSORI, M. & CHEN, M. A data-driven model for milling tool remaining useful life prediction with convolutional and stacked LSTM network. *Measurement* **154**, 107461. ISSN : 0263-2241. <https://www.sciencedirect.com/science/article/pii/S0263224119313284> (15 mars 2020).
117. TONG, Z., MIAO, J., TONG, S. & LU, Y. Early prediction of remaining useful life for Lithium-ion batteries based on a hybrid machine learning method. *Journal of Cleaner Production* **317**, 128265. ISSN : 0959-6526. <https://www.sciencedirect.com/science/article/pii/S095965262102480X> (1^{er} oct. 2021).

118. LIU, K., SHANG, Y., OUYANG, Q. & WIDANAGE, W. D. A Data-Driven Approach With Uncertainty Quantification for Predicting Future Capacities and Remaining Useful Life of Lithium-ion Battery. *IEEE Transactions on Industrial Electronics* **68**. Number : 4 Conference Name : IEEE Transactions on Industrial Electronics, 3170-3180. ISSN : 1557-9948 (avr. 2021).
119. LI, X., JIANG, H., LIU, Y., WANG, T. & LI, Z. An integrated deep multiscale feature fusion network for aeroengine remaining useful life prediction with multisensor data. *Knowledge-Based Systems* **235**, 107652. ISSN : 0950-7051. <https://www.sciencedirect.com/science/article/pii/S095070512100914X> (10 jan. 2022).
120. DING, Y., JIA, M., MIAO, Q. & HUANG, P. Remaining useful life estimation using deep metric transfer learning for kernel regression. *Reliability Engineering & System Safety* **212**, 107583. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832021001332> (1^{er} août 2021).
121. LI, S., LV, C., GUO, Z. & WANG, M. *Health condition-based maintenance decision intelligent reasoning method* in 2012 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering 2012 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (juin 2012), 405-408.
122. CHOI, S. S., KANG, K. S., KIM, H. G. & CHANG, S. H. Development of an on-line fuzzy expert system for integrated alarm processing in nuclear power plants. *IEEE Transactions on Nuclear Science* **42**. Conference Name : IEEE Transactions on Nuclear Science, 1406-1418. ISSN : 1558-1578 (août 1995).
123. XUE, Z., ZHANG, Y., CHENG, C. & MA, G. Remaining useful life prediction of lithium-ion batteries with adaptive unscented kalman filter and optimized support vector regression. *Neurocomputing* **376**, 95-102. ISSN : 0925-2312. <https://www.sciencedirect.com/science/article/pii/S0925231219313426> (1^{er} fév. 2020).
124. QIAN, Y., YAN, R. & GAO, R. X. A multi-time scale approach to remaining useful life prediction in rolling bearing. *Mechanical Systems and Signal Processing* **83**, 549-567. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327016302138> (15 jan. 2017).
125. ARIAS CHAO, M., KULKARNI, C., GOEBEL, K. & FINK, O. Fusing physics-based and deep learning models for prognostics. *Reliability Engineering & System Safety* **217**, 107961. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832021004725> (1^{er} jan. 2022).
126. SWANSON, D. *A general prognostic tracking algorithm for predictive maintenance* in 2001 IEEE Aerospace Conference Proceedings (Cat. No.01TH8542) 2001 IEEE Aerospace Conference Proceedings (Cat. No.01TH8542). **6** (mars 2001), 2971-2977 vol.6.
127. ZHOU, Z.-J., HU, C.-H., XU, D.-L., CHEN, M.-Y. & ZHOU, D.-H. A model for real-time failure prognosis based on hidden Markov model and belief rule base. *European Journal of Operational Research* **207**, 269-283. ISSN : 0377-2217. <https://www.sciencedirect.com/science/article/pii/S0377221710002596> (16 nov. 2010).
128. XIAHOU, T., ZENG, Z. & LIU, Y. Remaining Useful Life Prediction by Fusing Expert Knowledge and Condition Monitoring Information. *IEEE Transactions on Industrial Informatics* **17**. Number : 4 Conference Name : IEEE Transactions on Industrial Informatics, 2653-2663. ISSN : 1941-0050 (avr. 2021).
129. PHILLIPS, P. & DISTON, D. A knowledge driven approach to aerospace condition monitoring. *Knowledge-Based Systems* **24**, 915-927. ISSN : 0950-7051. <https://www.sciencedirect.com/science/article/pii/S0950705111000748> (1^{er} août 2011).

130. HU, Y., LIU, S., LU, H. & ZHANG, H. Remaining Useful Life Model and Assessment of Mechanical Products : A Brief Review and a Note on the State Space Model Method. *Chinese Journal of Mechanical Engineering* **32**. Number : 1, 15. ISSN : 2192-8258. <https://doi.org/10.1186/s10033-019-0317-y> (27 fév. 2019).
131. LEITE, G. d. N. P., ARAÚJO, A. M. & ROSAS, P. A. C. Prognostic techniques applied to maintenance of wind turbines : a concise and specific review. *Renewable and Sustainable Energy Reviews*. ISSN : 1364-0321. <http://www.sciencedirect.com/science/article/pii/S1364032117309383> (16 juin 2017).
132. LEE, J. *et al.* Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications. *Mechanical Systems and Signal Processing* **42**, 314-334. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327013002860> (1^{er} jan. 2014).
133. WANG, Y. *et al.* A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems. *Renewable and Sustainable Energy Reviews* **131**, 110015. ISSN : 1364-0321. <http://www.sciencedirect.com/science/article/pii/S1364032120303063> (1^{er} oct. 2020).
134. GE, M.-F., LIU, Y., JIANG, X. & LIU, J. A review on state of health estimations and remaining useful life prognostics of lithium-ion batteries. *Measurement* **174**, 109057. ISSN : 0263-2241. <https://www.sciencedirect.com/science/article/pii/S0263224121000890> (1^{er} avr. 2021).
135. LIPU, M. S. H. *et al.* A review of state of health and remaining useful life estimation methods for lithium-ion battery in electric vehicles : Challenges and recommendations. *Journal of Cleaner Production* **205**, 115-133. ISSN : 0959-6526. <http://www.sciencedirect.com/science/article/pii/S0959652618327793> (20 déc. 2018).
136. BERECIBAR, M. *et al.* Critical review of state of health estimation methods of Li-ion batteries for real applications. *Renewable and Sustainable Energy Reviews* **56**, 572-587. ISSN : 1364-0321. <http://www.sciencedirect.com/science/article/pii/S1364032115013076> (Supplement C 1^{er} avr. 2016).
137. KUMAR, A., GANDHI, C. P., ZHOU, Y., KUMAR, R. & XIANG, J. Latest developments in gear defect diagnosis and prognosis : A review. *Measurement* **158**, 107735. ISSN : 0263-2241. <https://www.sciencedirect.com/science/article/pii/S0263224120302736> (1^{er} juill. 2020).
138. WANG, D., TSUI, K.-L. & MIAO, Q. Prognostics and Health Management : A Review of Vibration Based Bearing and Gear Health Indicators. *IEEE Access* **6**. Conference Name : IEEE Access, 665-676. ISSN : 2169-3536 (2018).
139. SINGH, J., AZAMFAR, M., LI, F. & LEE, J. A systematic review of machine learning algorithms for prognostics and health management of rolling element bearings : fundamentals, concepts and applications. *Measurement Science and Technology* **32**. Publisher : IOP Publishing, 012001. ISSN : 0957-0233. <https://doi.org/10.1088%2F1361-6501%2F32%2F12001> (jan. 2020).
140. SIM, J., KIM, S., PARK, H. J. & CHOI, J.-H. A Tutorial for Feature Engineering in the Prognostics and Health Management of Gears and Bearings. *Applied Sciences* **10**. Number : 16 Publisher : Multidisciplinary Digital Publishing Institute, 5639. <https://www.mdpi.com/2076-3417/10/16/5639> (jan. 2020).
141. *Prognostics Center of Excellence - Data Repository* <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>.
142. SAXENA, A. & GOEBEL, K. PHM08 Challenge Data Set, NASA Ames Prognostics Data Repository. NASA Ames Research Center, Moffett Field, CA (2008).

143. SAXENA, A., GOEBEL, K. & EKLUND, N. *Damage propagation modeling for aircraft engine run-to-failure simulation* in (in Proc. IEEE Int. Conf. PHM, oct. 2008), 1-9.
144. AHMAD, W., KHAN, S. A. & KIM, J. M. A Hybrid Prognostics Technique for Rolling Element Bearings using Adaptive Predictive Models. *IEEE Transactions on Industrial Electronics* **PP**, 1-1. ISSN : 0278-0046 (2017).
145. KAI, G. & ALICE, A. Milling Data Set. *BEST lab, UC Berkeley. NASA Ames Prognostics Data Repository*. (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), %20NASA%20Ames%20Research%20Center,%20Moffett%20Field,%20CA (2007).
146. NECTOUX, P. *et al.* PRONOSTIA : An Experimental Platform for Bearings Accelerated Life Test. *IEEE International Conference on Prognostics and Health Management, Denver, CO, USA* (2012).
147. HASIB, S. A. *et al.* A Comprehensive Review of Available Battery Datasets, RUL Prediction Approaches, and Advanced Battery Management. *IEEE Access* **9**. Publisher : IEEE, 86166-86193. ISSN : 2169-3536. <https://ieeexplore.ieee.org/document/9454160/> (1^{er} jan. 2021).

Chapitre 2

Nouvelles approches hybrides de pronostic à base du GPR et IOWA

Résumé : Dans ce chapitre, nous proposons de nouvelles approches de fusion et de sélection pour prédire avec précision la durée de vie utile restante. Le schéma de fusion est construit via la combinaison des résultats fournis par un ensemble de modèles de régression à processus gaussien. Chaque régresseur est caractérisé par sa propre fonction de covariance et ses hyperparamètres initiaux. Dans ce contexte, nous adoptons la moyenne pondérée ordonnée induite comme outil de fusion pour réaliser une telle combinaison. Deux techniques de fusion supplémentaires basées sur les opérateurs de moyenne simple et de moyenne pondérée ordonnée, ainsi qu'une approche de sélection, sont mises en œuvre. Les différences entre les éléments adjacents des données d'entrée sont utilisées pour l'apprentissage au lieu des valeurs originales. Les résultats expérimentaux menés sur des données de batteries lithium-ion indiquent une amélioration significative des résultats obtenus. Ce travail peut contribuer au développement d'alternatives de fusion intelligentes et efficaces.

2.1 Introduction

De nos jours, l'estimation fiable de la durée de vie utile restante (RUL) avant l'apparition d'une défaillance ainsi que la prédiction de l'évolution du comportement de dégradation constituent un sujet intéressant pour les chercheurs universitaires et les ingénieurs industriels [1-3]. En se concentrant sur ces aspects, il est possible d'obtenir de nombreux avantages dans les systèmes complexes, par exemple la diminution du coût global du cycle de vie par la réduction des opérations de maintenance inutiles et des frais logistiques [4]. En général, la prédiction de la durée de vie utile peut être réalisée par trois méthodologies principales, les approches basées sur la physique, les approches guidées par les données et les approches hybrides [5]. Dans le cadre de cette dernière stratégie, l'agrégation des résultats associés aux différents modèles, basée sur un mécanisme de fusion vigilant, peut conduire à une amélioration de la performance de prédiction et présenter une meilleure efficacité par rapport aux techniques individuelles simples [6].

Malgré qu'un grand nombre de techniques de pronostic a été largement étudié dans la littérature, une stratégie de fusion basée sur l'opérateur IOWA n'a pas encore été utilisée à notre connaissance [1, 5, 7, 8]. Motivé par le succès de cette approche, notre objectif dans ce chapitre est de proposer une nouvelle approche de fusion pour l'estimation du RUL en combinant les prédictions d'un ensemble de modèles GPR en utilisant l'opérateur IOWA. Cependant, pour une estimation précise de RUL en agrégeant les prédictions d'un ensemble d'estimateurs à l'aide de l'opérateur de fusion IOWA, il est nécessaire de déterminer la composante d'ordre inducteur. La variance générée par le modèle GPR est utilisée comme valeur d'ordre inducteur dans la technique IOWA. En outre, deux autres mécanismes de fusion sont introduits : la fusion à base d'OWA et la fusion à base de moyenne. Nous proposons également une solution de sélection, où les valeurs de prédiction des modèles GPR combinés ayant une variance minimale sont choisies.

Selon les directives susmentionnées, les détails de notre travail sont élucidés dans ce qui suit. Tout d'abord, nous construisons un ensemble d'estimateurs GPR, où chaque modèle est caractérisé par ses propres hyperparamètres initiaux et/ou fonctions de covariance. Une phase préliminaire cruciale est nécessaire afin de transformer l'ensemble d'apprentissage initial en nouvelles données basées sur la transformation en différences. L'inclusion d'une telle transformation dans le cadre de la prédiction représente une contribution originale, où la différence entre deux points successifs est calculée et les valeurs entières obtenues sont considérées comme les nouvelles données d'apprentissage. Une meilleure variation du signal en fonction du temps peut être obtenue grâce à cette transformation, ce qui facilite l'analyse du comportement des données. Dans l'étape suivante, nous améliorons la performance de la prédiction en utilisant les trois approches de fusion proposées (Mean fusion, OWA fusion et IOWA fusion) plus une approche basée sur la sélection, que nous appelons « Min variance selection ». Comme les deux principaux inconvénients du IOWA résident dans la manière de sélectionner la valeur de l'ordre d'induction et les poids des opérateurs, nous optons pour la variance estimée autour des sorties de prédiction des modèles GPR comme valeur d'ordre d'induction et les poids associés sont estimés à partir des données

d'apprentissage prédites. Cette méthodologie est basée sur l'algorithme proposé et inspiré de la technique de descente de gradient adoptée dans les réseaux de neurones artificiels [9-11].

La section 2.2 de ce chapitre est consacrée à un état de l'art. Cet état de l'art est réservé essentiellement à la présentation de quelques travaux connexes dans la littérature. La section 2.3 présente les principaux concepts liés aux techniques GPR et IOWA, respectivement. Dans la section 2.4, nous détaillons de manière rigoureuse les différentes composantes des approches proposées. Les résultats expérimentaux sont présentés dans la section 2.5, où une comparaison est effectuée en termes de critères de performance par rapport à certaines études similaires. Nous terminons ce chapitre par des remarques finales et des orientations de travaux futures.

2.2 Etat de l'art

Il convient de mentionner que certaines procédures d'agrégation ont été adoptées par les chercheurs pour prédire la durée de vie utile restante à l'aide de techniques de fusion basées sur les résultats fournis par divers modèles [12-14]. La moyenne de modèles bayésiens (BMA) est une méthode de fusion utilisée pour combiner des modèles de machine à vecteur de pertinence (RVM) avec différentes fonctions noyaux afin d'estimer la durée de vie utile restante des batteries lithium-ion [15]. Dans Du et al [16], la méthode du vote majoritaire (MVM) est appliquée pour fusionner les sorties de prédiction fournies par un ensemble de réseaux neuronaux artificiels (RNA). Cette étude est consacrée à la prédiction du processus de dégradation des roulements, où l'intégration de l'optimisation par essaims de particules et du recuit simulé a été développée pour la sélection du sous-ensemble optimal à combiner. Hu et al [12] ont proposé des procédures de pondération comprenant la pondération basée sur la précision, la pondération basée sur la diversité et la pondération basée sur l'optimisation dans le but de déterminer un vecteur de poids approprié pour un ensemble de quatre algorithmes basés sur des données. Le processus de pondération est fondé sur une métrique d'erreur évaluée à l'aide d'une validation croisée k-fold. Les auteurs Xu et al [13] ont calculé la séquence d'erreurs relatives pour trois méthodes de pronostic différentes, la régression de Dempster-Shafer (DSR), les machines à vecteurs de support (SVM) et les RNA. Dans l'approche de fusion basée sur la théorie de la comomentropie, le coefficient de pondération associé est déduit comme l'inverse de la métrique d'erreur calculée. Dans He et al [17], une approche de fusion basée sur l'analyse en ondelettes et les méthodes de régression par processus gaussien (GPR) est proposée pour estimer l'état de santé des batteries lithium-ion. La méthode d'analyse en ondelettes est adoptée pour décomposer le signal original en un signal approximatif et un ensemble de signaux détaillés à différentes échelles. Les estimateurs GPR proposés sont approuvés pour s'adapter à la dégradation globale, à la régénération locale et aux fluctuations des séries chronologiques de l'état de santé. Les résultats de la prédiction finale sont obtenus en combinant les résultats fournis par tous les modèles GPR proposés.

Un nouveau type d'opérateurs d'agrégation, appelé opérateur OWA (Ordered Weighted Averaging), a été introduit par le travail pionnier de Yager [18]. Plus tard, cette vision a été améliorée pour donner un cadre plus précis connu sous le nom de moyenne pondérée ordonnée induite (IOWA) [9]. L'opérateur d'agrégation général approuvé dans les deux approches offre non seulement un outil facile à utiliser, mais aussi un outil très compétitif accrédité dans plusieurs domaines tels que les applications environnementales, la chimio-métrie, l'analyse des réseaux sociaux, l'ontologie, le raisonnement à base de cas et la prise de décision [19-22]. L'idée innovante d'OWA est l'étape de réorganisation dans laquelle les valeurs des arguments sont d'abord réorganisées de la valeur la plus élevée à la valeur la plus faible. Ensuite, ces valeurs classées sont exploitées dans le contexte de la procédure connue de calcul de moyenne pondérée. Au lieu de l'ordre basé sur la valeur adoptée dans OWA, les arguments dans IOWA sont classés par une autre composante appelée valeur d'ordre inductrice, qui généralise l'OWA standard.

Parmi les techniques reconnues dans le domaine du pronostic, la méthode probabiliste et non paramétrique, connue sous le nom de régression par processus gaussien, a suscité un intérêt majeur. Cela peut être justifié par sa facilité d'utilisation et sa rapidité de prédiction par rapport aux autres méthodes de régression basées sur les données [23, 24]. De plus, la régression par processus gaussien est caractérisée par sa flexibilité et sa capacité à fournir une variance autour de sa prédiction moyenne, ce qui permet de représenter l'incertitude au niveau du modèle. Il faut souligner que même sans la disponibilité d'un modèle physique, le paradigme GPR permet d'élaborer des prédictions précises [25].

2.3 Description des techniques adoptées

Dans cette section, nous donnons un aperçu des techniques utilisées pour l'élaboration de notre approche de fusion proposée, qui sont exprimées par la technique de régression par processus gaussien et les opérateurs IOWA.

2.3.1 Régression par processus gaussien

Un processus gaussien (GP) est un modèle probabiliste et non paramétrique définissant une distribution sur des fonctions. Il est considéré comme un ensemble de variables aléatoires, qui ont une distribution gaussienne conjointe multivariée [23]. Le GP est un processus stochastique $f(x)$ spécifié par sa fonction moyenne $m(x)$ et sa fonction de covariance $k(x, x')$, qui représente la covariance entre deux observations x et x' [25]. Les expressions analytiques de ces deux fonctions peuvent être écrites par les équations 2.1 et 2.2 :

$$m(x) = E[f(x)] \quad (2.1)$$

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (2.2)$$

Le processus gaussien est noté par :

$$f(x) \sim GP(m(x), k(x, x')) \quad (2.3)$$

La composante clé de la méthode du processus gaussien est la fonction de covariance car elle permet de coder les hypothèses concernant la fonction inconnue à apprendre. N'importe quelle fonction peut être traitée comme une fonction de covariance. De nombreuses instances couramment utilisées de ces fonctions sont exprimées, y compris leurs propriétés, dans Rasmussen et Williams [23]. En combinant plusieurs types de fonctions de covariance simples, il est possible de construire une fonction de covariance plus complexe capable de modéliser les données de manière adéquate.

Dans les problèmes de régression, un modèle GP est exprimé comme une somme de la fonction linéaire latente $f(x)$ et d'un bruit blanc gaussien additif ϵ , comme indiqué par l'équation 2.4 :

$$y = f(x) + \epsilon \quad (2.4)$$

où le bruit blanc additif gaussien suit une distribution normale de moyenne nulle et d'écart type $\epsilon \sim N(0, \sigma_{ns}^2)$ (l'indice ns dans σ_{ns}^2 indique le bruit). La distribution antérieure de y sur l'observation bruitée devient :

$$Cov(y) = K(X, X) + \sigma_{ns}^2 I \quad (2.5)$$

et la distribution conjointe antérieure d'une valeur cible y et d'une valeur de prédiction des données de test f_* peut être décrite comme suit :

$$\begin{bmatrix} y \\ f_* \end{bmatrix} \sim N \left(\begin{bmatrix} m(X) \\ m(X_*) \end{bmatrix}, \begin{bmatrix} K(X, X) + \sigma_{ns}^2 I & K(X, X_*) \\ K(X_*, X) & K(X_*, X_*) \end{bmatrix} \right) \quad (2.6)$$

où $m(x)$ et K sont la fonction moyenne et la matrice de covariance du processus gaussien respectivement, tandis que X et X_* représentent les cas utilisés pour l'apprentissage et le test. I et σ_{ns}^2 désignent la matrice d'identité et la variance du bruit, respectivement. La sortie de test f_* est calculée selon la distribution postérieure avec l'équation prédictive clé pour la régression du processus gaussien :

$$f_* | X, y, X_* \sim N(\bar{f}_*, cov(f_*)), \quad (2.7)$$

où

$$\bar{f}_* = m(X_*) + K(X_*, X)[K(X, X) + \sigma_{ns}^2 I]^{-1}(y - m(X))$$

et

$$cov(f_*) = K(X_*, X_*) - K(X_*, X)[K(X, X) + \sigma_{ns}^2 I]^{-1}K(X, X_*)$$

avec $m(X)$ et $m(X_*)$ représentent la moyenne des données d'apprentissage et la moyenne des données de test, respectivement.

Les fonctions de moyenne et de covariance contiennent des paramètres libres appelés hyperparamètres, qui seront ajustés en fonction des données d'apprentissage en maximisant la vraisemblance marginale. Cette mesure est obtenue par marginalisation sur la fonction latente, comme indiqué par l'équation 2.8 :

$$\log(y|X, \theta) = -\frac{1}{2}y^T(K + \sigma_{ns}^2 I)^{-1}y - \frac{1}{2}\log(|K + \sigma_{ns}^2 I|) - \frac{nt}{2}\log(2\pi) \quad (2.8)$$

où θ est le vecteur connexe des hyperparamètres, nt désigne le nombre de données d'apprentissage et I désigne la matrice unitaire de dimension nt . Une solution approximative pour ce problème de maximisation peut être obtenue en utilisant une technique de recherche basée sur le gradient [23].

À ce niveau de développement, deux questions fondamentales se posent dans le cadre de la régression par processus gaussien. La première concerne la définition du modèle global et de la fonction de covariance, tandis que la seconde concerne l'ajustement des hyperparamètres employés. Néanmoins, l'optimalité de ces paramètres n'est pas toujours assurée et même s'ils sont obtenus, ils ne constituent pas dans certaines situations le meilleur choix [26].

La fusion de différents modèles peut être considérée comme une solution puissante pour contourner l'influence d'une sélection inappropriée de la fonction de covariance ou d'une mauvaise initialisation des hyperparamètres. En raison de la robustesse de l'approche IOWA, elle peut être adoptée comme un candidat potentiel pour réaliser le schéma de fusion.

2.3.2 Opérateurs de moyenne pondérée ordonnée induits (IOWA)

La technique OWA (Ordered Weighted Averaging Operator) est considérée comme un ensemble paramétré d'opérateurs d'agrégation de type moyenne, où la moyenne standard est un cas particulier de ces nouveaux opérateurs. Une caractéristique importante de ces opérateurs qui les rend non linéaires est l'étape de réorganisation dans laquelle les arguments sont classés par leurs valeurs. Dans les lignes suivantes, nous présentons les opérateurs OWA tels définis par Yager [18].

L'opérateur OWA de dimension n peut être formulé comme une cartographie à valeurs multiples :

$$F : R^n \rightarrow R^n \quad (2.9)$$

auquel est attribué un vecteur de pondération noté par $W = [w_j, j = 1..n]^T$ tel que :

$$w_j \in [0, 1] \quad (2.10)$$

$$\sum_{j=1}^n w_j = 1 \quad (2.11)$$

et

$$F(a_1, a_2, \dots, a_n) = \sum_{j=1}^n w_j b_j \quad (2.12)$$

où b_j est le $j^{\text{ème}}$ plus grand élément de a_i . L'aspect principal de cet opérateur est l'étape de classement où le poids w_j n'est pas associé à un argument particulier a_j mais à l'argument ayant la $j^{\text{ème}}$ position dans le classement. Par analogie avec le calcul de la moyenne, l'agrégation par les opérateurs OWA/IOWA satisfait les critères de monotonie, de commutativité, d'idempotence et de bornage ($\text{Min}(a_i) \leq F(a_1, a_2, \dots, a_n) \leq \text{Max}(a_i)$) [18].

Si nous supposons les formes simples suivantes pour le vecteur de pondération W : $W = [\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n}]^T$, $W = [1, 0, 0, \dots, 0]^T$ et $W = [0, 0, \dots, 0, 1]^T$ respectivement, on peut facilement montrer que l'opérateur OWA contient les opérateurs Moyenne, Maximum et Minimum comme cas particuliers. L'agrégation OWA offre plus de flexibilité car il ne s'agit pas des cas extrêmes spécifiés par le "et" et le "ou" standards. Elle permet plutôt d'ajuster implicitement le degré de "et" et de "ou" dans le processus [18]. Pour caractériser le degré de "et" et "ou", Yager a défini une mesure appelée *Orness*. Une deuxième mesure appelée *Dispersion* est proposée pour calculer le niveau de déploiement de l'information dans les arguments lors d'une agrégation basée sur le vecteur de pondération W [9] :

$$\text{Orness}(W) = \frac{1}{n-1} \sum_{i=1}^n (n-i)w_i \quad (2.13)$$

et

$$\text{Disp}(W) = \sum_{i=1}^n w_i \ln(w_i) \quad (2.14)$$

La méthode IOWA est proposée comme un type générique non linéaire des opérateurs OWA, tel introduit par Yager dans Yager et Filev [9]. Cette méthode étendue diffère de l'OWA standard dans l'étape de réorganisation, où les valeurs des arguments sont classées sur la base d'une composante auxiliaire appelée valeur inductrice au lieu des valeurs des arguments. De nouvelles classes d'opérateurs OWA sont discutées dans les références Yager R. [27, 28] et Merigó et al. [29]. Le principal problème de l'agrégation OWA et IOWA est l'obtention des poids associés w_i . De nombreuses approches ont été proposées pour générer ces poids depuis les premières propositions des deux méthodes [10, 11, 19].

Dans la section suivante, nous décrivons en détail l'approche de fusion proposée.

2.4 Description du cadre de fusion proposé

Considérons un ensemble de données d'apprentissage $Y = \{t, f(t)\}_{t=1}^{n_{\text{train}}}$ avec t désigne l'indice temporel des données observées et $f(t) = y_t$ correspond aux valeurs disponibles

des données observées et représente l'indicateur d'état reflétant le comportement de dégradation dans le processus. La paire (t, y_t) désigne respectivement les vecteurs d'entrée et de sortie. Le paramètre n_{train} est la longueur des données cibles.

Étant donné l'ensemble de données d'apprentissage Y , nous visons à prédire le comportement de dégradation continue pour le prochain temps de test $t = n_{train} + 1, n_{train} + 2, \dots, n_{train} + n_{test}$ avec l'objectif d'estimer la durée de vie utile restante. La taille de l'ensemble de données de test est exprimée par le paramètre n_{test} .

Pour atteindre cet objectif, nombreux modèles GPR sont proposés et mis en œuvre pour les tâches de prédiction. Il convient de mentionner que les sorties de ces modèles sont agrégées afin d'améliorer les performances de prédiction en introduisant trois approches de fusion. La première est la fusion à base de moyenne simple, la seconde est la fusion à base d'OWA et enfin la fusion basée sur la technique IOWA. Une autre alternative de fusion réside dans une procédure de sélection, où la valeur de prédiction ayant la plus faible variance est choisie à chaque instant t .

Dans la figure 2.1, nous résumons les étapes principales de l'approche proposée et nous fournissons une description détaillée de chaque étape dans les sous-sections suivantes.

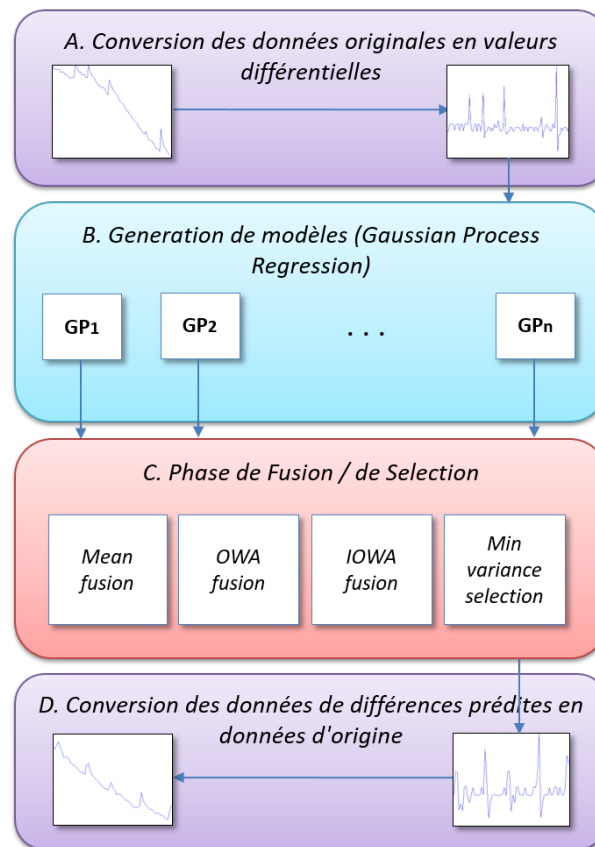


FIGURE 2.1 – Illustration des étapes principales de l'approche proposée

2.4.1 Conversion des données originales en valeurs différentielles

Dans nombreux cas, il est important de transformer les données sous une forme plus appropriée, car cela offre divers avantages statistiques lors de l'exploitation. En effet, une

telle transformation peut aider à révéler nombreuses hypothèses, notamment la normalité et l'homogénéité de la variance. En outre, la procédure de transformation rend les unités des attributs comparables, même sur des échelles distinctes. En général, la transformation des données peut être effectuée soit d'une manière monotone où les modifications sont réalisées pour chaque valeur de la matrice de données indépendamment des autres valeurs, soit par relativisation en utilisant certains standards de la ligne ou de la colonne de la matrice. La transformation monotone contient de nombreuses variantes telles que les transformations de puissance, logarithmique et racine carrée *arcsine*, tandis que la transformation de relativisation peut être liée à des mesures statistiques comme la moyenne et la somme. Par exemple, l'ajustement à la moyenne ou à l'écart-type et la transformation binaire par rapport à la moyenne ou à l'écart-type sont deux classes largement explorées dans la pratique. Si nos données sont issues d'une série temporelle, il est possible de manipuler la différence des valeurs entre des dates consécutives au lieu des données initiales, de manière analogue à la dérivée première d'une courbe de série temporelle. En effet, cette transformation des différences peut être appliquée également pour la $n^{\text{ième}}$ différence en exécutant la transformation des différences récursivement n fois. En pratique, cela signifie que la deuxième différence est la même que la différence des données différenciées résultantes. En outre, si nos données sont un vecteur de longueur l , alors la transformation des différences renvoie un vecteur de longueur $l - 1$. Sinon, si les données sont une matrice non vide de nr par nc , alors la transformation des différences renvoie une matrice de taille $(nr - 1)$ par nc , dont les éléments sont les différences entre les lignes de la matrice. Ainsi, les données générées peuvent donner lieu à des variations plus expressives par rapport au temps en représentant une distribution normale autour des moyennes proches de zéro [30].

Dans ce contexte, nous adoptons la transformation en différences sur des éléments adjacents afin d'obtenir des caractéristiques de données adéquates en plus de rendre le signal plus pertinent à l'analyse. Un indicateur d'état approprié devrait refléter le comportement de dégradation d'un système surveillé, ce qui aide à l'évaluation de la dégradation future. Pour préserver la tendance à la dégradation du signal prédit et réduire les résultats de prédiction aberrants, la différence entre les éléments adjacents des données d'apprentissage est utilisée à la place des valeurs originales. La transformation proposée s'effectue comme suit :

Considérons d_t comme la différence entre deux valeurs observées successives, $d_t = y_{t+1} - y_t$ par laquelle nous obtenons un nouvel ensemble de données d'apprentissage $D_{\text{train}} = \{t, d_t\}_{t=1}^{n_{\text{train}}-1}$.

La procédure de restauration des valeurs de données prédites originales est présentée dans la dernière partie de cette section.

2.4.2 Génération des modèles de régression par processus gaussien

Dans cette étape, nous construisons un ensemble de n estimateurs GPR déterminés par leurs propres fonctions de covariance. D'une manière standard, nous pouvons sélectionner un ensemble de modèles ayant les mêmes fonctions de covariance conjointement avec des initialisations aléatoires des hyperparamètres. Afin d'augmenter la diversité de l'ensemble

et d'assurer l'indépendance entre les estimateurs, il est plus intéressant de considérer différents modèles avec des fonctions de covariance distinctes.

2.4.3 Fusion avec les opérateurs IOWA

L'objectif principal de cette phase est de combiner les différentes sorties de prédiction des modèles GPR générés en utilisant les opérateurs OWA et IOWA. Ainsi, considérons $\langle p_{tj}, v_{tj} \rangle = GPR_j(t)$ où p_{tj} et v_{tj} signifient la valeur de prédiction et la variance correspondante pour le temps t fournies par le $j^{ème}$ estimateur GPR.

Afin d'agrèger les résultats obtenus par l'ensemble des modèles GPR utilisant les opérateurs de fusion OWA et IOWA, nous devons construire le vecteur B appelé vecteur d'arguments classés. Il est alors possible de formuler les opérateurs de fusion OWA et IOWA en utilisant une notation vectorielle :

$$F_{OWA}(p_{t1}, p_{t2}, \dots, p_{tn}) = W_{OWA}^T B_{OWA} \quad (2.15)$$

$$F_{IOWA}(p_{t1}, p_{t2}, \dots, p_{tn}) = W_{IOWA}^T B_{IOWA} \quad (2.16)$$

où F est l'opérateur de fusion et p_{tj} sont les arguments agrégés, W_{OWA} et W_{IOWA} représentent les vecteurs de pondération de OWA et IOWA, respectivement. Les vecteurs B_{OWA} et B_{IOWA} sont liés aux arguments classés, où les éléments dans B_{OWA} sont classés par leurs valeurs en ordre décroissant et pour les éléments dans B_{IOWA} , nous utilisons $-v_{tj}$ pour classer les arguments en ordre décroissant. Dans cette procédure de classement, une plus grande importance est attribuée aux valeurs prédites p_{tj} ayant une petite variance v_{tj} , où $-v_{tj}$ représente la valeur d'ordre inductrice.

2.4.3.1 Détermination des poids

La détermination du vecteur des poids W étant d'une importance cruciale dans plusieurs domaines d'applications où nombreuses stratégies ont été proposées pour sa spécification. Dans la littérature, nombreuses techniques sont élaborées et dédiées à cette tâche, notamment les techniques d'optimisation, les techniques basées sur des arguments et les techniques d'apprentissage à base de données [19]. Dans les dernières techniques, nous apprenons les poids à partir des données d'apprentissage observées p_{tj} , où $t = 1 : n_{train} - 1$, $j = 1 : n$. Le processus d'apprentissage est basé sur la méthode de descente de gradient comme expliqué dans l'algorithme présenté dans [9-11].

Notre objectif est d'obtenir un vecteur de poids $W = [w_1, w_2, \dots, w_n]^T$ en préservant la condition 2.17

$$W^T B_t = d_t |_{t=1:n_{train}-1} \quad (2.17)$$

où $B_t = [b_{t1}, b_{t2}, \dots, b_{tn}]$ représente le vecteur ordonné de la sortie $(p_{t1}, p_{t2}, \dots, p_{tn})$ fournie par les estimateurs GPR_j , et d_t la valeur correspondante aux données d'apprentissage observées. Les éléments du vecteur de poids W satisfont les conditions 2.10 et 2.11.

Les poids $\{w_i\}_{i=1:n}$ approximant les opérateurs d'agrégation sont obtenus en optimisant les erreurs instantanées e_t comme indiqué dans l'équation 2.18 :

$$e_t = \frac{1}{2}(b_{t1}w_1 + b_{t2}w_2 + \dots + b_{tn}w_n - d_t)^2 \quad (2.18)$$

L'ajout des conditions 2.10 et 2.11 à ce problème d'apprentissage donne lieu à un problème d'optimisation sous contrainte. Afin d'éliminer les contraintes imposées aux poids w_i , Yager a défini chaque poids de la manière suivante [17] :

$$w_i = \frac{e^{\lambda_i}}{\sum_{j=1}^n e^{\lambda_j}}, i = 1 : n \quad (2.19)$$

où λ est un paramètre auxiliaire.

En effectuant cette transformation, on passe d'un problème de minimisation sous contrainte à un problème de programmation non linéaire sans contrainte, qui peut être résolu par la méthode de descente de gradient. Le résultat final de cette phase est exprimé par les vecteurs de pondération W_{OWA} et W_{IOWA} .

2.4.3.2 Agrégation / Sélection des différences prédites des données de test

A ce stade, il est possible de réaliser l'agrégation des valeurs de test prédites par les n différents modèles GPR par un simple calcul de moyenne. Pour une agrégation plus sophistiquée, il est fortement recommandé de réaliser la fusion en considérant des techniques plus élaborées comme OWA et IOWA, où deux étapes de base sont nécessaires pour leur application. La première est l'étape de réorganisation dans laquelle les données de test prédites $(p_{t1}, p_{t2}, \dots, p_{tn})$ pour $t = ntrain, ntrain + 1, \dots, ntrain + ntest - 1$ sont classer par leur valeur pour la méthode OWA et par la valeur négative de leur variance correspondante pour les opérateurs IOWA. La deuxième étape est la moyenne pondérée basée sur les vecteurs de pondération W_{OWA} et W_{IOWA} tels qu'obtenus dans la dernière phase.

Par conséquent, nous obtenons trois stratégies de fusion : La fusion à base de moyenne, la fusion à base d'OWA et la fusion à base d'IOWA. Comme approche alternative, au lieu de réaliser l'agrégation sur les données de test prédites, nous pouvons adopter une procédure de sélection en prenant la valeur prédite p_{tj} ayant la variance minimale v_{tj} pour chaque entrée t .

2.4.4 Conversion des données de différences prédites en données d'origine

En conséquence, nous obtenons la prédiction des différences des valeurs adjacentes liées aux données de test et nous devons récupérer le domaine du signal original du RUL prédit. Ainsi, nous ajoutons la première valeur de différence prédite \hat{d}_{ntrain} à la dernière valeur y_{ntrain} au données d'apprentissage pour obtenir la première donnée de test prédite $\hat{y}_{ntrain+1}$. La déduction des valeurs prédites restantes est établie de la même manière en utilisant la formule suivante $\hat{y}_{t+1} = \hat{y}_t + \hat{d}_t$ pour $t = ntrain + 1$ à $ntrain + ntest$.

Une description récapitulative de la fusion à base de moyenne proposée, de la fusion à base de IOWA et de la sélection à base de minimum variance est fournie dans les algorithmes 2.1, 2.2 et 2.3. Il convient de mentionner que la fusion à base d'OWA n'est pas décrite en raison de sa similitude avec l'algorithme de fusion à base de IOWA, où la seule différence se situe au niveau de la phase de réorganisation.

Algorithm 2.1: Mean fusion

Input	$Y_{train} = \{t, y_t\}$ pour $t = 1 : n_{train}$
Output	Résultat moyenne \hat{Y}_{test}
Step 1	Effectuer la transformation en différences $d_t = y_{t+1} - y_t$ pour $t = 1 : n_{train} - 1$
Step 2	Générer n modèles GPR et réaliser la prédiction telle que : $\langle p_{tj}, v_{tj} \rangle = GPR_j(t), t = n_{train} \text{ à } n_{train} + n_{test} - 1$ (prédiction des différences des données d'apprentissage)
Step 3	Calculer la moyenne des données de test prédites $\hat{d}_t = Mean(\hat{d}_{tj})$ pour $t = n_{train} \text{ à } n_{train} + n_{test} - 1$ et $j = 1 : n$
Step 4	Calculer les valeurs originales \hat{Y}_{test} $\hat{y}_{n_{train}} = y_{n_{train}}$ $\hat{y}_{t+1} = \hat{y}_t + \hat{d}_t$ pour $t = n_{train} \text{ à } n_{train} + n_{test}$
End	

Comme mentionné précédemment, il est possible de démontrer que la fusion à base de IOWA admet la fusion à base de moyenne, la fusion à base d'OWA et la sélection à base de minimum variance comme des cas particuliers. Ceci est prouvé en choisissant les vecteurs de poids $W = [\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n}]^T$ et $W = [1, 0, 0, \dots, 0]^T$ pour représenter la fusion à base de moyenne et la sélection de variance minimale, respectivement. Si nous sélectionnons la valeur de l'ordre inducteur égale à la valeur de l'argument, nous obtenons la fusion à base d'OWA.

2.5 Données expérimentales et résultats

Le jeu de données utilisé dans le cadre de notre travail, connu sous le nom d'ensemble de données des batteries, est obtenu à partir du référentiel de données du Centre d'excellence en pronostic (PCoE) de la NASA. Ainsi, les valeurs extraites sont étudiées pendant l'exécution des expériences de pronostic. Dans ce qui suit, nous fournissons une description détaillée des caractéristiques de la batterie, où un ensemble de quatre batteries de type Lithium-ion (5, 6, 7 et 18) fonctionnent à température ambiante sous trois régimes distincts : charge, décharge et impédance. Le régime de charge est caractérisé par un mode de courant constant (CC) à 1,5A jusqu'à ce que la tension de la batterie atteigne une valeur de 4,2V. Ensuite, la tension continue dans un mode de tension constante (CV) jusqu'à la chute du courant de charge à une valeur de 20mA. Dans le régime de décharge, le niveau de courant

Algorithm 2.2: IOWA fusion

Input	$Y_{train} = \{t, y_t\}$ où $t = 1 : n_{train}$
Output	Résultat de la fusion \hat{Y}_{test}
<hr/>	
Step 1	Effectuer la transformation en différences $d_t = y_{t+1} - y_t$ pour $t = 1 : n_{train} - 1$
Step 2	Générer n modèles GPR et réaliser la prédiction telle que : $\langle p_{tj}, v_{tj} \rangle = GPR_j(t), t = n_{train} \text{ à } n_{train} + n_{test} - 1$ (prédiction des différences des données d'apprentissage)
Step 3	Réorganiser les données d'apprentissage prédites en fonction de $-v_{tj}$: $B_{train} = \{b_{tj}\}$ pour $t = 1 : n_{train} - 1$ et $j = 1 : n$ où b_{tj} est le $j^{ème}$ p_{tj} avec la plus grande $-v_{tj}$ (plus petite variance) En cas d'égalité dans l'opération de classement, on prend la moyenne des éléments liés
Step 4	Minimiser $W_{IOWA}^T B_{train} = D_{train}$ basé sur la transformation en utilisant l'algorithme de descente de gradient comme suggéré dans Yager et Filev [9].
Step 5	Réorganiser les données de test prédites en fonction de $-v_{tj}$: $B_{test} = \{b_{tj}\}, t = n_{train} \text{ à } n_{train} + n_{test} - 1$ et $j = 1 : n$ où b_{tj} est le $j^{ème}$ p_{tj} avec la plus grande $-v_{tj}$ (plus petite variance)
Step 6	Appliquer la procédure d'agrégation $\hat{D}_{test} = W^T B_{test}$
Step 7	Calculer les valeurs originales \hat{Y}_{test} $\hat{y}_{n_{train}} = y_{n_{train}}$ $\hat{y}_{t+1} = \hat{y}_t + \hat{d}_t$ pour $t = n_{train} \text{ à } n_{train} + n_{test}$
End	

est maintenu constant (CC) avec une valeur de 2A jusqu'à ce que la tension de la batterie soit réduite à 2,7V, 2,5V, 2,2V et 2,5V pour les batteries étiquetées 5, 6, 7 et 18, respectivement. Pour le dernier régime concernant le profil d'impédance, les mesures sont effectuées sur la base d'une fréquence de spectroscopie d'impédance électrochimique variant dans l'intervalle [0,1Hz : 5kHz]. La répétition des cycles de charge/décharge conduit à une dégradation monotone des performances de la batterie, tandis que les mesures offrent des indications sur les paramètres inhérents à la batterie affectés par la progression de dégradation. Il convient de préciser que les tests sont interrompus lorsque le critère de fin de vie (EoL) des batteries est atteint, ce qui correspond à une diminution de trente pour cent de la capacité nominale (de 2Ahr à 1,4Ahr) [31].

L'estimation de l'état de santé (SOH) associé aux batteries de type lithium-ion est l'un des indicateurs d'état vitaux exploités pour le PHM des appareils alimentés par batterie. L'une des méthodes approuvées pour déterminer le SOH d'une batterie est basée sur la capacité

Algorithm 2.3: Min variance selection

Input	$Y_{train} = \{t, y_t\}$ où $t = 1 : n_{train}$
Output	Résultat sélectionné \hat{Y}_{test}
Step 1	Effectuer la transformation en différences $d_t = y_{t+1} - y_t$ pour $t = 1 : n_{train} - 1$
Step 2	Générer n modèles GPR et réaliser la prédiction telle que : $\langle p_{tj}, v_{tj} \rangle = GPR_j(t), t = n_{train} \text{ à } n_{train} + n_{test} - 1$ (prédiction des différences des données d'apprentissage)
Step 3	Compléter la procédure de la sélection $\hat{d}_t = \hat{d}_{tj}$ avec une minimum v_{tj} pour $t = n_{train} \text{ à } n_{train} + n_{test} - 1$ et $j = 1 : n$
Step 4	Calculer les valeurs originales \hat{Y}_{test} $\hat{y}_{n_{train}} = y_{n_{train}}$ $\hat{y}_{t+1} = \hat{y}_t + \hat{d}_t$ pour $t = n_{train} \text{ à } n_{train} + n_{test}$
End	

exprimée par l'équation 2.20

$$SOH = \frac{C_i}{C_0} \times 100 \quad (2.20)$$

où C_i désigne la $i^{\text{ème}}$ grandeur de capacité dégradée avec les cycles et C_0 indique la capacité initiale [32].

Dans l'expérience suivante, nous choisissons les données de la batterie n° 5 pour apprentissage et test. Ce choix est essentiellement motivé par l'exploitation abondante des données de cette batterie dans plusieurs travaux, ce qui facilite les tâches d'évaluation et de comparaison ultérieures. Dans la figure 2.2, nous décrivons l'état de quatre batteries utilisées dans les expériences. On peut observer que le comportement général des courbes SOH pour toutes les batteries à une tendance monotone incluant quelques fluctuations, ce qui peut rendre la tâche de prédiction plus difficile à réaliser.

La figure 2.3 représente les valeurs de dégradation de SOH allant du cycle 1 au cycle 168, où la période globale est divisée en données d'apprentissage et données de test. Dans ce cas, les ensembles de données d'apprentissage et de test sont représentés par $Y_{train} = \{t, SOH(t)\}_{t=1}^{100}$ et $Y_{test} = \{t, SOH(t)\}_{t=101}^{168}$, respectivement. Les cycles allant de 1 à 100 sont sélectionnés comme entrée d'apprentissage dans la procédure de prédiction et ceux allant de 101 à 168 sont sélectionnés comme entrée pour l'étape de test. Le $SOH(t)$ correspondant est évalué pour représenter les données d'apprentissage et de test, respectivement. Puisque la régression par processus gaussien est considérée comme un modèle non paramétrique, les données d'apprentissage Y_{train} en plus de valeurs d'entrée de test t (t représente le nombre de cycles allant de 101 à 168) dans l'étape de prédiction peuvent être utilisées comme entrée du modèle GPR avec des hyper-paramètres optimaux.




FIGURE 2.2 – Evolution de critère SOH des batteries en fonction de nombre de cycle

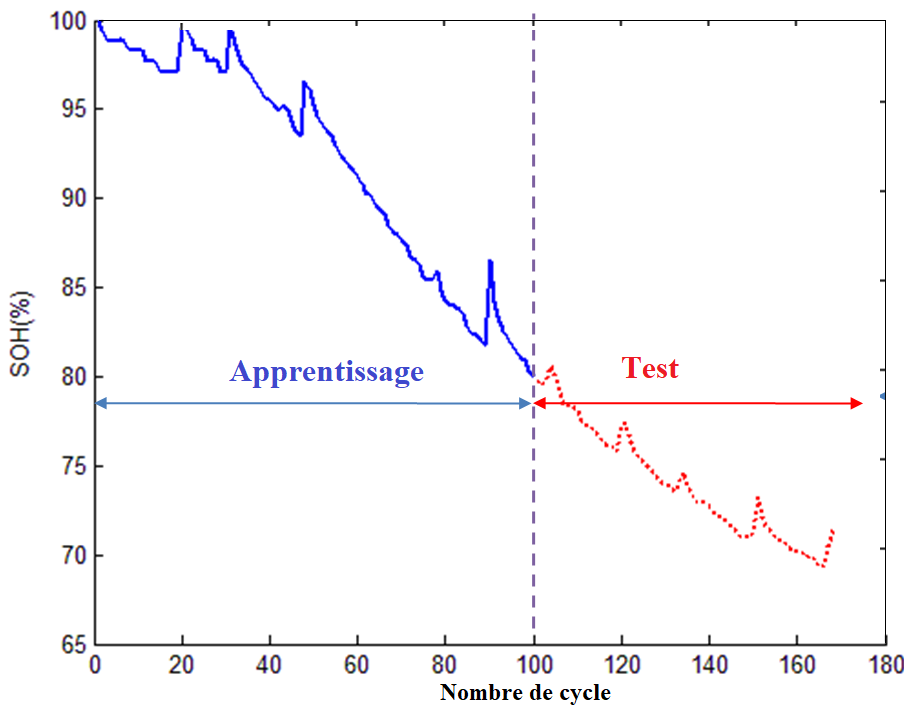


FIGURE 2.3 – Illustration de mesure SOH de batterie No. 5 avec les deux régions d'apprentissage et de test

Dans certaines conditions de fonctionnement, le processus de dégradation de la batterie montre des tendances anormales, où la capacité disponible augmente dans certains cycles. Ces fluctuations sont reconnues comme des phénomènes d'auto-charge ou de régénération

[32]. La prise en charge de ces variations est un aspect obligatoire à satisfaire par des prédicteurs robustes.

Dans les prochaines sous-sections, nous présentons et discutons les résultats obtenus associés à l'application des différentes phases constituant l'approche proposée.

2.5.1 Conversion des données originales en valeurs de différence

Les résultats de cette première étape sont illustrés dans la figure 2.4. Dans la partie supérieure, les données d'apprentissage originales sont représentées et leurs différences correspondantes sont visualisées dans la partie inférieure, qui représente les nouvelles données d'apprentissage. La courbe des données obtenues reflète la présence d'une variation périodique en plus de quelques irrégularités. L'existence conjointe de ces deux composantes motive la sélection de certaines fonctions de covariance appropriées. Par conséquent, la fonction périodique (PER) est sélectionnée pour modéliser la variation périodique conjointement avec chacune des fonctions de covariance suivantes : Squared Exponential (SE), Eye, Noise, Neural Network (NN), Underdamped Linear Langevin (ULL) et Matérn(Matern), qui sont choisies pour modéliser le terme d'irrégularités [23].

2.5.2 Génération des modèles de régression par processus gaussien

Nous comparons et évaluons l'approche proposée selon dix scénarios. Dans le premier, nous construisons un ensemble d'estimateurs GPR avec une fonction de covariance simple (Squared Exponential) et différentes initialisations des hyperparamètres. Du deuxième au septième scénario, nous construisons un ensemble de modèles GPR basés sur des fonctions de covariance conjointement avec l'utilisation du PER et l'une des sept fonctions de covariance proposées pour le terme d'irrégularités. En procédant ainsi, il est plus probable d'obtenir un bon ajustement des données. Les deux fonctions de covariance avec différentes initialisations des hyperparamètres sont considérées séparément pour ces scénarios. Une fonction de covariance composite du PER avec les fonctions SE, Eye et Noise est sélectionnée afin de modéliser les estimateurs GPR pour les trois derniers scénarios, respectivement.

Les configurations des dix scénarios sont présentées dans le tableau 2.1. Dans la première phase d'apprentissage, les hyperparamètres liés à chaque estimateur GPR sont initialisés avec des valeurs aléatoires dans la plage [0 :15], et ils sont ensuite optimisés en utilisant la maximisation de la fonction de vraisemblance logarithmique [23].

Après l'apprentissage des trente estimateurs GPR, nous appliquons les modèles obtenus pour prédire la dégradation du SOH des prochains cycles associés à l'ensemble de données de test. En conséquence, on obtient trente vecteurs représentant les trente prédictions des RUL des données de test. Ces vecteurs estimés peuvent être agrégés dans le but d'améliorer les résultats du pronostic. Un nombre de 500 expériences est réalisé pour chaque scénario, où le modèle associé à la meilleure erreur d'apprentissage est choisi.




FIGURE 2.4 – Transformation des données d'apprentissage en valeurs de gradient

2.5.3 Fusion avec les opérateurs IOWA

Dans cette expérience, les trois approches de fusion proposées sont appliquées, à savoir la fusion à base de moyenne, la fusion à base d'OWA et la fusion à base de IOWA, en plus d'une approche de sélection appelée sélection de variance minimale.

À cet égard, l'utilité des nouvelles approches de fusion proposées est mise en évidence par les mauvaises performances de prédiction lorsqu'elles sont basées sur un modèle GPR

TABLE 2.1 – Fonctions de covariance utilisées pour générer les ensembles de différentes expériences

COV	Expression	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
SE	$k_{SE} = \sigma^2 \exp\left(-\frac{(x_i - x_j)^2}{2l^2}\right)$	30	15	x	x	x	x	x	x	x	x
PER	$k_p = \sigma^2 \exp\left(-\frac{2}{l^2} \sin^2\left(\frac{w}{2\pi}(x_i - x_j)\right)\right)$	x	15	15	15	15	15	15	x	x	x
EYE	$k_{EYE} = \delta_{ij}$ où δ_{ij} est la fonction delta de Kronecker	x	x	15	x	x	x	x	x	x	x
NOISE	$k_{NOISE} = \sigma^2 \delta_{ij}$ où δ_{ij} est la fonction delta de Kronecker	x	x	x	15	x	x	x	x	x	x
NN	$k_{NN} = \frac{2}{\pi} \sin^{-1}\left(\frac{2\tilde{X}^T \Sigma \tilde{X}'}{\sqrt{(1+2\tilde{X}^T \Sigma \tilde{X})(1+2\tilde{X}'^T \Sigma \tilde{X})}}\right)$ où $\tilde{X} = (1, X_1, \dots, X_d)$ est un vecteur d'entrée augmenté	x	x	x	x	15	x	x	x	x	x
ULL	$k_{ULL} = \frac{\sigma^2}{2\beta k} e^{-\alpha x_i - x_j } (\cos w(x_i - x_j) + \frac{\alpha}{w} \sin w x_i - x_j)$ avec $\alpha = \frac{\beta}{2m}$, $w = \frac{1}{m} \sqrt{mk - \beta^2/4}$ et $m, \beta, k, \sigma > 0$	x	x	x	x	x	15	x	x	x	x
Matérn	$k_{Matérn}(r) = \frac{2^{1-\nu}}{\Gamma(\nu)} \left(\frac{\sqrt{2\nu r}}{l}\right)^\nu K_\nu\left(\frac{\sqrt{2\nu r}}{l}\right)$ où Γ est la fonction gamma, K_ν est la fonction de Bessel modifiée Cas plus intéressants pour l'apprentissage automatique : $\nu = 3/2$ et $\nu = 5/2$. $\nu = 3/2$ est optée dans ce travail	x	x	x	x	x	x	15	x	x	x
COMP1	$k_{COMP1} = k_p + k_{SE}$	x	x	x	x	x	x	x	30	x	x
COMP2	$k_{COMP2} = k_p + k_{EYE}$	x	x	x	x	x	x	x	x	30	x
COMP3	$k_{COMP3} = k_p + k_{NOISE}$	x	x	x	x	x	x	x	x	x	30

élémentaire et sur une procédure de fusion négligeant l'étape de transformation des différences, comme le montrent les figures 2.5 et 2.6, respectivement.

Les résultats de prédiction illustrés sur la figure 2.5 montrent clairement les limites d'un




FIGURE 2.5 – Prédiction du critère SOH à base de la fonction de covariance SE




FIGURE 2.6 – Prédiction du critère SOH basée sur une procédure de fusion simple sans l'étape de transformation en différences

modèle GPR de base dans l'estimation du critère SOH des données expérimentales. En outre, la figure 2.6 confirme que les techniques de fusion et de sélection proposées, qui ne

tirent pas parti de la transformation des différences, échouent dans la détection de la dégradation continue du comportement du SOH.

Les résultats de prédiction basés sur les techniques proposées pour les dix scénarios sont présentés dans les figures 2.7, 2.8 et 2.9, respectivement.

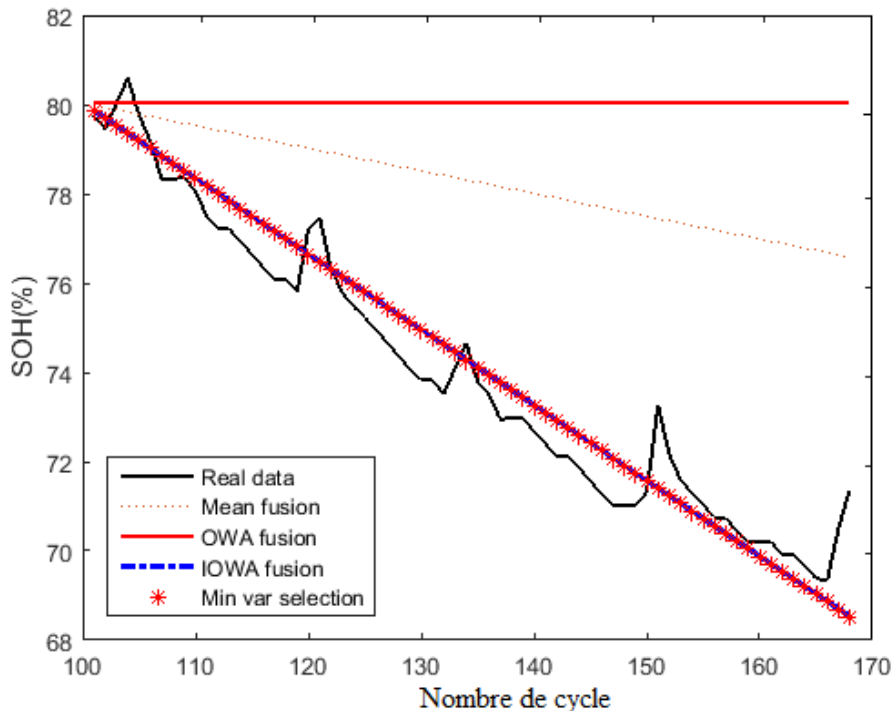


FIGURE 2.7 – Prédiction du critère SOH basée sur la fusion des fonctions de covariance SE (trente initialisations pour les hyperparamètres)

Nous observons sur la figure 2.7 que les prédictions basées sur la fusion IOWA et la sélection de la variance minimale expliquent plus précisément l'évolution de la mesure SOH puisqu'elles présentent des meilleures prédictions par rapport aux approches de fusion basées sur la moyenne et sur OWA. Les résultats de la prédiction de la figure 2.7 indiquent que les fluctuations connues dans le domaine des batteries comme le phénomène d'auto-recharge ne sont pas capturées. Cette remarque met en évidence la faiblesse de la fusion d'estimateurs GPR modélisés avec des fonctions de covariance de base, bien qu'ils fournissent de bons résultats de prédiction. En revanche, les courbes prédites par les approches de fusion IOWA et de sélection de la variance minimale suivent la variation réelle du SOH, comme le montre la figure 2.8. Les deux approches sont meilleures que les techniques de fusion à base de moyenne et à base d'OWA, avec la détection du phénomène d'auto-recharge dans tous les scénarios, mais moins bien détectée par l'approche de fusion IOWA pour les scénarios S4, S6 et S7. Il ressort clairement de ces figures que les approches de fusion à base de moyenne et à base d'OWA ont la plus mauvaise capacité de prédiction, où l'écart entre les courbes prédites résultantes et le SOH réel est important. En outre, nous pouvons remarquer que certains résultats de prédiction associés aux trois derniers scénarios basés sur la fusion IOWA et la sélection de la variance minimale dans la figure 2.9 sont à peu près similaires à leurs homologues liés aux autres scénarios dans la figure 2.8. En effet, nous utilisons pour

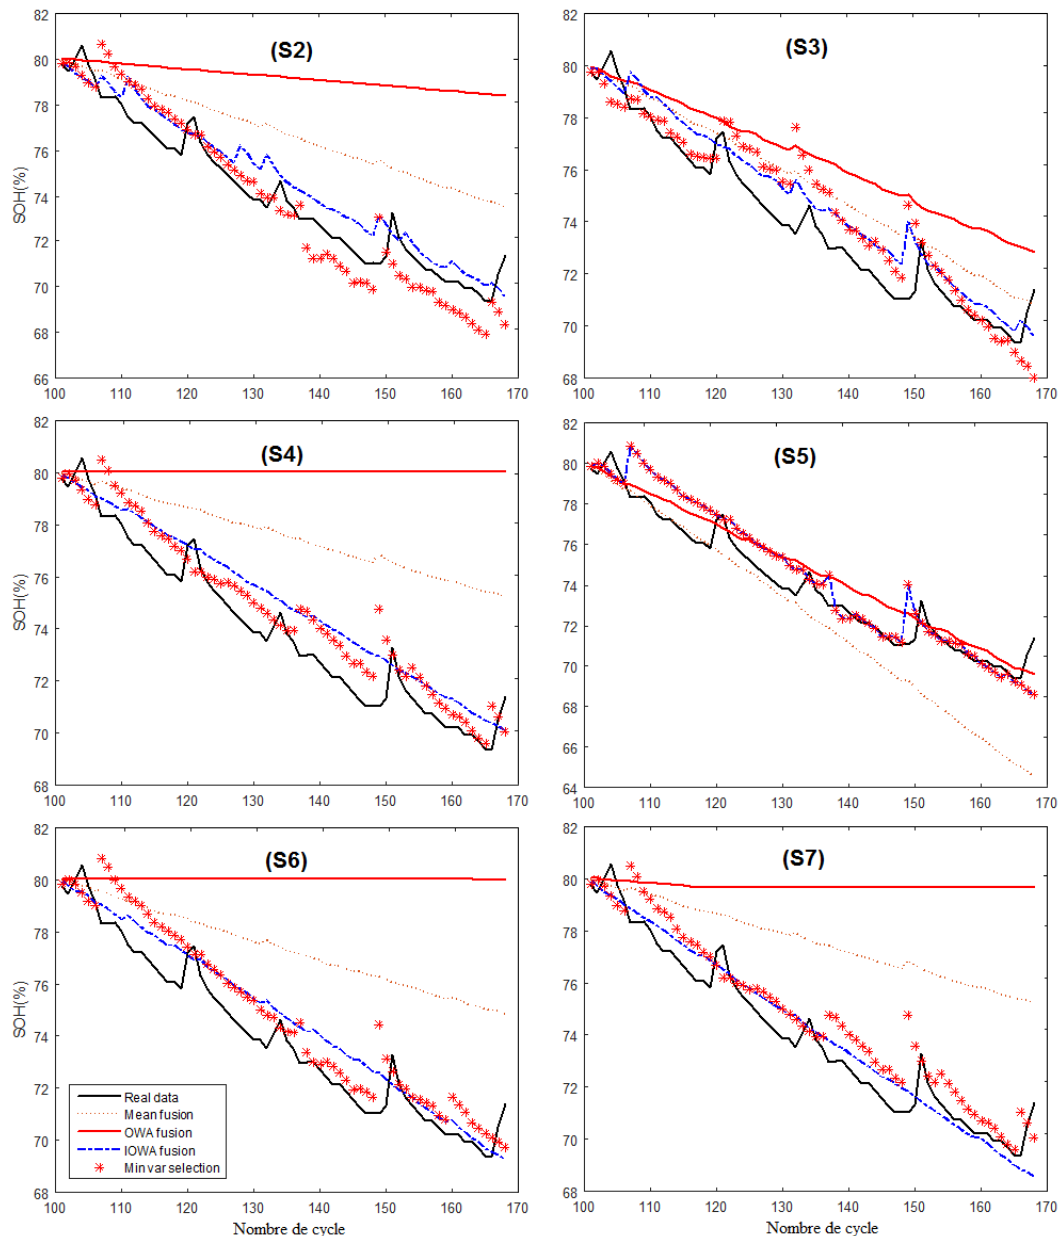


FIGURE 2.8 – Prédiction du critère SOH basée sur la fusion des fonctions de covariance périodiques conjointement avec les fonctions de covariance additionnelles proposées pour chaque scénario (quinze initialisations des hyper-paramètres pour chaque modèle)

ces scénarios 30 modèles GPR. Par exemple, dans le deuxième scénario, 15 modèles avec une fonction de covariance PER ayant trois hyper-paramètres et 15 modèles avec une fonction SE ayant deux hyper-paramètres sont spécifiés. Pour le huitième scénario, 30 estimateurs GPR avec une fonction de covariance composite $COMP = PER + SE$ sont générés. Ainsi, dans le cas du deuxième scénario, nous devons ajuster trente modèles avec trois hyper-paramètres dans les 15 premiers modèles et deux hyper-paramètres dans les 15 autres modèles, pour chaque GPR. Pour le huitième scénario, il est nécessaire, de manière analogue, d'optimiser 30 modèles GPR avec cinq (3 + 2) hyper-paramètres pour chaque modèle, ce qui peut entraîner des charges supplémentaires en temps et en mémoire. Du point de vue de la complexité

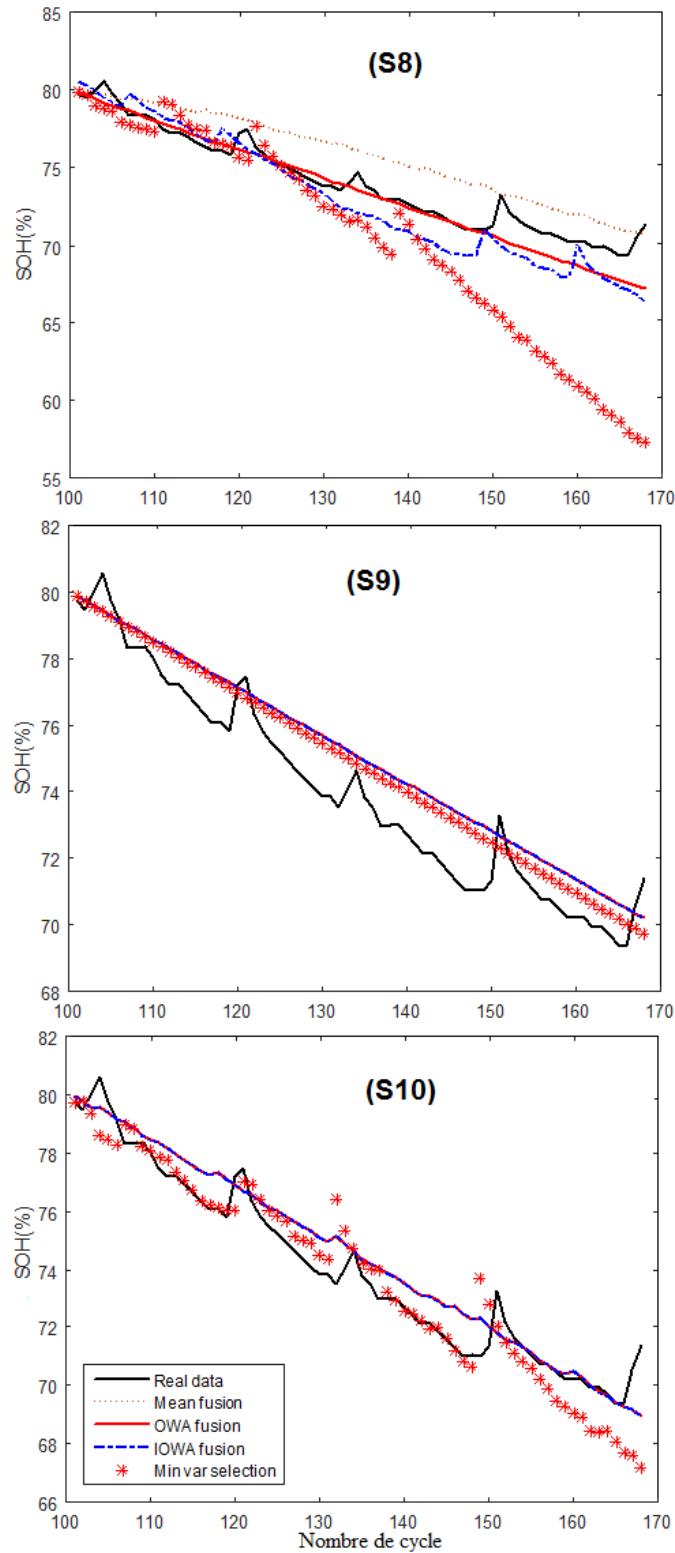


FIGURE 2.9 – Prédiction du critère SOH basée sur la fusion de fonctions de covariance composites (trente initialisations pour les hyper-paramètres)

de calcul, la procédure d'optimisation nécessite moins de temps dans le cas du deuxième scénario, ce qui la rend plus adéquate pour les applications de pronostic en ligne. La réduction du temps et des coûts de mémoire peut être justifiée dans le cas du deuxième scénario

par le fait que l'optimisation effectuée sur des ensembles séparés d'hyperparamètres nécessite moins d'efforts par rapport à l'optimisation effectuée sur un ensemble composite, ce qui sera prouvé plus tard lorsque nous discuterons la consommation de temps CPU. D'après la figure 2.9, les prédictions basées sur la fusion à base d'OWA et la fusion à base de moyenne sont améliorées car les résultats fournis par les modèles GPR générés se rapprochent de la variation réelle du SOH.

Pour démontrer les avantages obtenus par la fusion et la procédure de sélection adoptées dans l'approche proposée, nous représentons sur la même figure (2.10) différents résultats fournis par les estimateurs GPR et le résultat de la fusion correspondante. Les courbes de couleur grise sont celles attribuées aux différentes prédictions de SOH et utilisées dans l'agrégation.

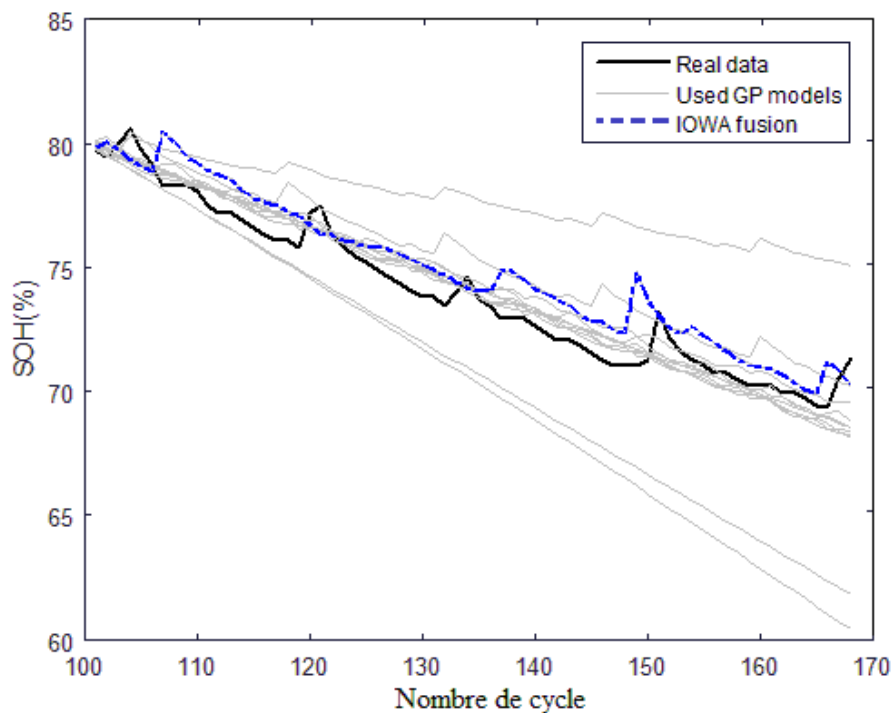


FIGURE 2.10 – Comparaison des estimateurs GPR et du résultat de fusion correspondant

Pour une évaluation critique des dix scénarios sur une base quantitative, nous utilisons l'erreur quadratique moyenne (RMSE) pour effectuer cette comparaison, comme le montre le tableau 2.2. Le RMSE peut être écrite sous une forme compacte comme suit :

$$RMSE = \sqrt{\frac{\sum_{i=1}^{ntest} (y_i - \hat{y}_i)^2}{ntest}} \quad (2.21)$$

où y_i et \hat{y}_i représentent respectivement les valeurs réelles et estimées et $ntest$ désigne le nombre d'échantillons de test.

On peut déduire de ce tableau que l'approche de fusion à base de IOWA fournit les meilleurs résultats et que la sélection de variance minimal vient en deuxième position avec un certain écart.

TABLE 2.2 – Résultats des prédictions pour les dix scénarios appliqués à la batterie n°5

Méthodes		Expérience									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Méthodes de fusion	Mean fusion	4.77	3.05	1.59	4.01	2.36	3.74	4.01	1.97	0.87	1.26
	OWA fusion	6.76	5.82	2.69	6.76	1.03	6.76	6.46	1.13	0.87	1.26
	IOWA fusion	0.80	1.06	1.11	1.27	1.17	1.08	0.80	1.66	0.87	1.26
Méthode de sélection	Min variance selection	0.80	1.21	1.37	1.17	1.17	1.22	1.17	5.31	1.08	1.07

Pour valider l'approche proposée, nous appliquons la même méthodologie aux autres batteries restantes (6, 7 et 18). L'analyse quantitative de ces batteries basée sur les quatre approches proposées et les dix scénarios est résumée dans les tableaux 2.3, 2.4 et 2.5, respectivement.

TABLE 2.3 – Résultats des prédictions pour les dix scénarios appliqués à la batterie n°6

Méthodes		Expérience									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Méthodes de fusion	Mean fusion	5.41	2.23	3.32	3.16	2.69	3.68	2.16	2.72	2.02	0.94
	OWA fusion	7.25	6.54	11.27	6.84	4.12	6.68	7.25	3.36	2.02	4.37
	IOWA fusion	2.24	4.19	6.41	1.30	1.43	1.30	1.30	4.07	2.02	1.70
Méthode de sélection	Min variance selection	2.24	2.61	5.68	2.71	2.71	3.78	2.71	1.50	5.87	2.63

TABLE 2.4 – Résultats des prédictions pour les dix scénarios appliqués à la batterie n°7

Méthodes		Expérience									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Méthodes de fusion	Mean fusion	2.84	1.82	2.63	2.71	1.26	2.89	4.07	0.63	0.53	1.04
	OWA fusion	5.35	2.67	4.74	4.41	2.81	5.32	4.11	0.53	0.53	1.04
	IOWA fusion	0.54	0.75	0.62	0.56	0.98	0.50	0.81	2.37	0.53	1.04
Méthode de sélection	Min variance selection	0.54	1.00	1.00	0.72	0.72	0.72	0.72	0.73	0.72	1.01

TABLE 2.5 – Résultats des prédictions pour les dix scénarios appliqués à la batterie n°18

Méthodes		Expérience									
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Méthodes de fusion	Mean fusion	2.05	3.08	2.29	2.32	4.38	2.19	2.53	3.91	4.03	3.65
	OWA fusion	1.66	2.72	2.59	1.74	1.80	1.65	1.85	4.33	4.03	4.15
	IOWA fusion	4.29	4.59	5.31	4.33	2.67	4.11	3.96	3.17	4.03	4.12
Méthode de sélection	Min variance selection	4.29	3.02	1.73	3.08	4.43	2.72	3.08	4.18	3.20	4.17

En analysant les résultats de la prédiction, nous constatons que la fusion à base de IOWA fournit en général les meilleures performances, suivie par la méthode de sélection. La performance des résultats du IOWA est due à la deuxième phase d'apprentissage consacrée à la détermination des poids du IOWA.

En outre, presque tous les résultats obtenus associés à la fusion du IOWA et à la sélection de la variance minimale sont compétitifs, comme l'expliqueront les résultats des comparaisons suivantes dans ce travail. Ces résultats compétitifs prouvent la robustesse des deux approches proposées puisqu'elles ne sont pas altérées par l'utilisation de fonctions de covariance différentes. Selon les scénarios 1 à 10, nous pouvons déduire que les fonctions de

covariance SE utilisées pour la fusion dans le premier scénario fournissent des résultats satisfaisants dans certaines situations en termes de RMSE mais malheureusement le phénomène d'auto-recharge n'est pas capturé.

Bien que les résultats obtenus en utilisant la fusion à base de moyenne montrent les meilleurs résultats en termes de RMSE pour certaines configurations, il est inévitable de remarquer que l'approche de fusion à base de moyenne n'est pas stable comme le confirment les scénarios S1 à S7. Il est à souligner que le pronostic du SOH lié à la batterie n° 18 présente des résultats moins précis dans les expériences comme indiqué dans le tableau 2.5. Ceci peut être dû à la présence d'effets physiques altérant la dégradation du SOH comme l'exprime la courbe de cette batterie dans la figure 2.2. Par conséquent, le développement d'outils fiables produisant de bons résultats pour diverses batteries peut s'avérer une mission lourde, voire inextricable, surtout lorsqu'elle est soumise à des contraintes réalistes.

Dans la figure 2.11, nous mettons en évidence certains résultats obtenus pour ces batteries, où la fusion à base de IOWA et l'approche de sélection confirment leur bonne capacité à détecter les phénomènes de régénération.

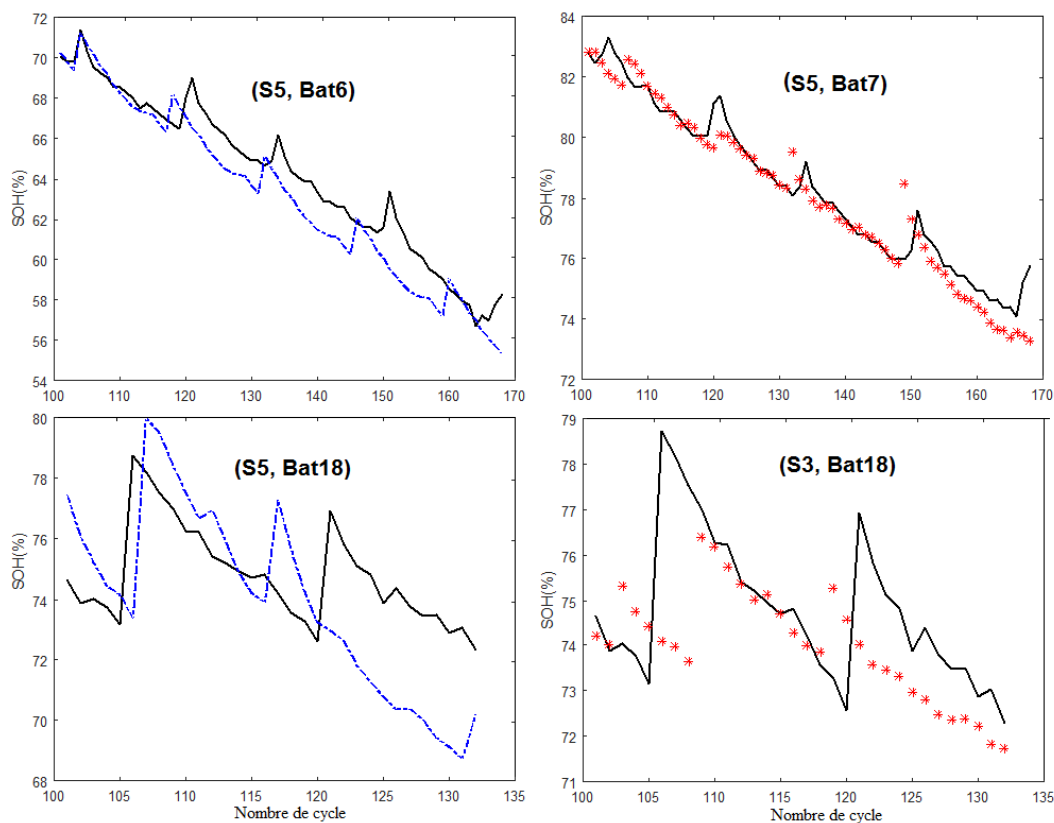


FIGURE 2.11 – Prédiction du critère SOH basée sur la fusion des fonctions de covariance périodiques conjointement avec les fonctions de covariance additionnelles proposées pour les scénarios 3 et 5 (batteries 6,7 et 18)

Le temps CPU consommé est un facteur important pour évaluer la performance de toute approche proposée. Il convient de mentionner que pour plus de transparence dans la comparaison du temps CPU, il est important de séparer le temps consommé dans l'exécution des modèles GPR du temps nécessaire aux procédures de fusion ou de sélection. Dans ce

but, nous pouvons considérer que les approches proposées sont structurées en deux étapes. La première étape est l'exécution des modèles GPR tandis que les procédures de fusion et de sélection sont considérées comme la deuxième étape. Le tableau 2.6 présente le temps CPU consommé par chaque méthode en secondes pour chaque scénario dans une réplication. Ces expériences sont réalisées sur un PC équipé de Windows 10, d'un processeur AMD Ryzen 5 3400G CPU@ 3.70 GHz, de 16 Go de RAM et d'un système 64 bits.

TABLE 2.6 – Consommation de temps en secondes pour les dix scénarios appliqués à la batterie no.5

Phase	Expérience									
	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
Exécution des GPRs	48.60	86.26	66.92	61.46	99.30	83.12	74.97	427.57	67.35	125.74
Fusion à base de OWA	4.01	4.09	4.13	3.90	3.93	4.09	4.08	4.39	3.61	3.64
Fusion à base de IOWA	4.00	4.02	4.06	4.03	4.10	4.00	4.10	4.04	3.53	3.55
Sélection de variance minimale	0.01	0.01	0.01	0.01	0.01	0.01	0.02	0.02	0.01	0.01

Il ressort clairement du tableau 2.6 que la fonction de covariance composite adoptée dans les trois derniers scénarios nécessite plus de temps avec 427, 67 et 125 secondes respectivement. Ainsi, nous avons besoin de 86, 66 et 61 secondes pour les scénarios S2, S3 et S4, ce qui démontre qu'il est préférable de considérer séparément les fonctions de covariance au lieu de les combiner en une fonction de covariance composite. Les temps d'exécution consommés par les modèles composites sont proportionnels au nombre d'hyper-paramètres utilisés dans l'étape d'optimisation, où nous avons 6, 3 et 4 hyper-paramètres pour S8, S9 et S10 respectivement. Le temps d'exécution dans la phase de fusion des deux techniques OWA et IOWA est le même, soit 4 secondes, qui sont nécessaires pour la procédure d'optimisation par descente de gradient. En effet, on peut considérer que 4 secondes sont négligeables par rapport au temps CPU total, mais elles sont relativement importantes par rapport au temps consommé par la méthode de sélection de variance minimale. Le temps total consommé est significatif lorsqu'il est calculé en 500 répétitions pour chaque expérience. Par exemple, nous avons besoin pour le deuxième scénario de $86 \times 500 = 43000$ secondes (12 heures) pour l'exécution des modèles GP et de $4 \times 500 = 2000$ (33 minutes) pour l'exécution de la phase de fusion IOWA. Au total, nous avons besoin de 12 heures pour les expériences de sélection et de 33 minutes supplémentaires pour réaliser la méthode du IOWA. En effet, 500 répétitions pour la sélection du modèle est un nombre important, qui est fixé pour offrir plus d'informations sur les résultats obtenus. Pour cette raison, nous avons besoin de certaines caractéristiques utiles pour révéler la robustesse de la fusion à base de IOWA et de la sélection de la variance minimale. Les figures 2.12 et 2.13 comparent les performances des 500 modèles créés pour chaque scénario lié à la batterie 5 en termes de RMSE des données de test. La figure 2.12 représente les RMSEs des données prédites pour les 250 premières réplications associées à chaque scénario lié à la batterie 5 pour les deux techniques IOWA et sélection de minimum variance. Nous choisissons seulement 250 modèles dans le but d'une visualisation claire des résultats et la même tendance est observée dans les 250 modèles restants. Dans la figure 2.13, nous montrons des diagrammes en boîte représentant la distribution des RMSEs pour les données de test obtenues par les 500 modèles, qui sont utilisés

pour sélectionner le meilleur dans chaque scénario.

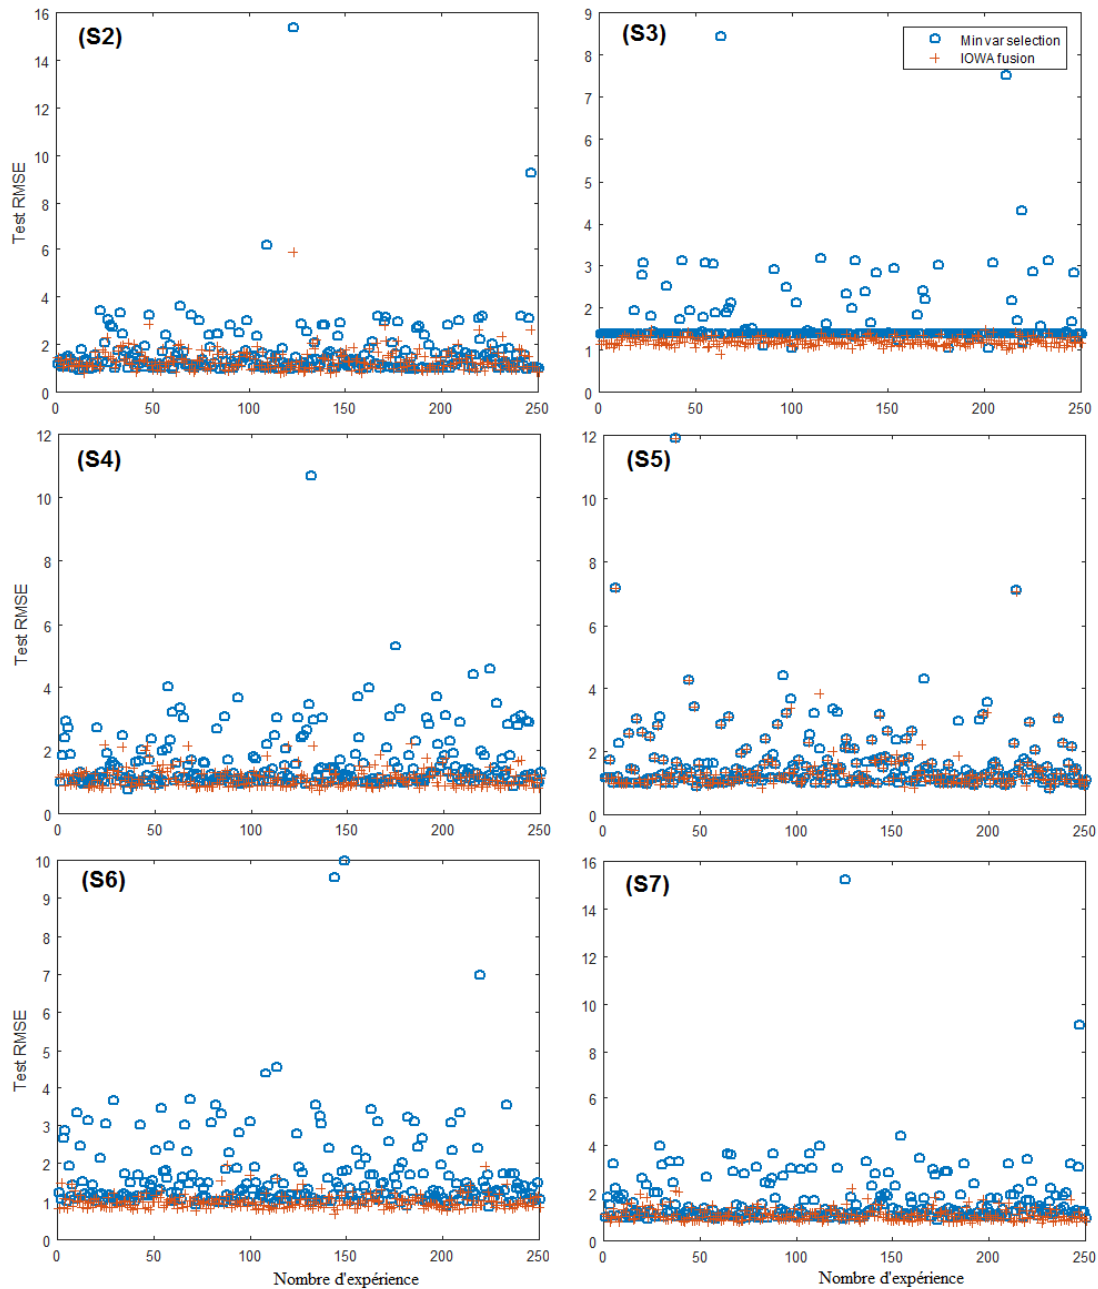


FIGURE 2.12 – Variation des valeurs RMSE du test en fonction du nombre de répétitions de l'expérience

La figure 2.12 montre clairement que de nombreux modèles générés par les méthodes de fusion IOWA et de sélection de la variance minimale pour tous les scénarios sont généralement acceptables en termes de valeurs RMSE, ce qui confirme la performance des deux approches proposées. Par rapport à la méthode de sélection de la variance minimale, les modèles générés par l'approche de fusion à base de IOWA sont plus prometteurs. La figure 2.13 confirme cette observation, où les diagrammes en boîte relatifs à la méthode de fusion IOWA montrent une bonne distribution des erreurs des modèles générés. Par exemple,

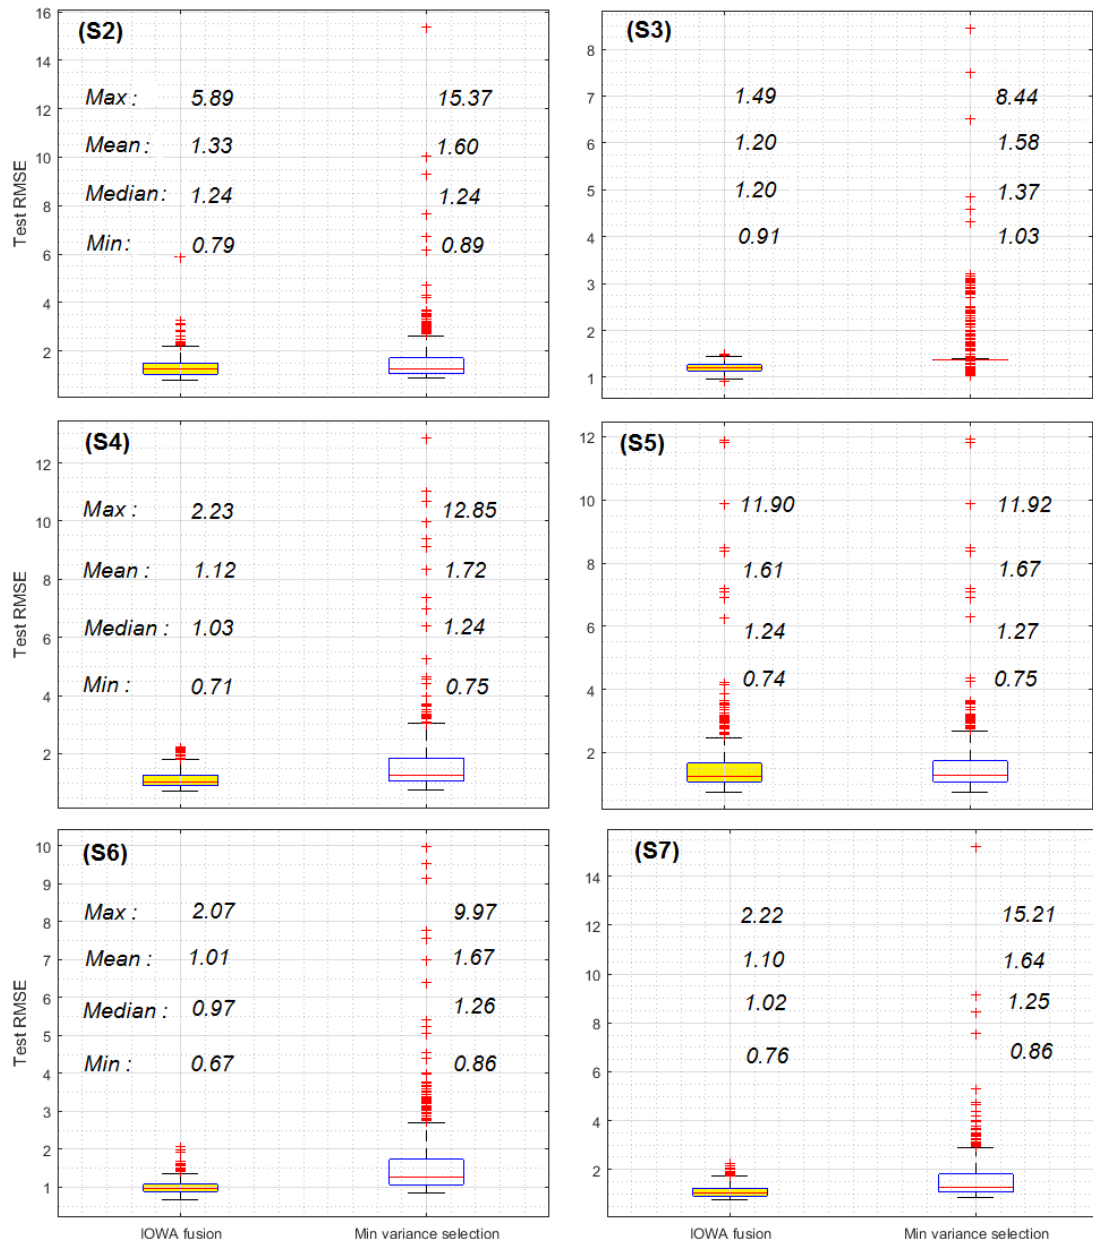


FIGURE 2.13 – Présentation des diagrammes en boîte associés aux valeurs RMSE du test pour les deux techniques

toutes les erreurs quadratiques moyennes (RMSE) de test des modèles générés par la méthode de fusion IOWA pour les scénarios S3, S4, S6 et S7 sont inférieures à 1.49, 2.23, 2.08 et 2.22 respectivement. En outre, ces erreurs sont regroupées autour de leurs valeurs médianes 1.20, 1.03, 0.97 et 1.02 respectivement. Par conséquent, un petit nombre de répétitions d'expériences dans l'étape de sélection du modèle peut être considéré comme suffisant pour l'adoption de la méthode de fusion IOWA. Par exemple, l'adoption de 20 répétitions pour chaque expérience semble suffisante pour la technique de fusion IOWA. La figure 2.14 présente 20 diagrammes en boîte représentant dix ensembles de 20 éléments de valeurs de RMSE de test, qui sont liés aux deux approches de fusion IOWA et de sélection de variance minimale. Dans cette figure, le diagramme en boîte avec le numéro impair (i) désigne la

méthode de fusion IOWA tandis que le diagramme en boîte de l'approche de sélection de variance minimale est représenté par le numéro pair ($i + 1$) pour le même ensemble. Comme le montre cette figure, 20 répétitions d'expériences suffisent pour adopter la méthode de fusion IOWA, contrairement à la technique de sélection de la variance minimale, qui nécessite un plus grand nombre de répétitions d'expériences, comme le confirment les diagrammes en boîte associés. À titre d'exemple, l'exécution de 20 expériences du deuxième scénario nécessite $86 \times 20 = 1720$ (28.66 minutes) pour réaliser la phase d'exécution des modèles GPR et $4 \times 20 = 80$ secondes pour réaliser la phase de fusion IOWA. En ce qui concerne les répétitions d'expériences pour achever la procédure de sélection de la variance minimale (pour laquelle plusieurs réplifications sont obligatoires), 86 secondes par réplification supplémentaire sont nécessaires, ce qui est supérieur au temps consommé par la phase de fusion de l'IOWA dans les 20 expériences. Pour cette raison, nous pouvons considérer que l'approche de fusion IOWA prend moins de temps que la méthode de sélection de la variance minimale, car cette dernière nécessite un plus grand nombre de répétitions d'expériences.

Dans le tableau 2.7, nous elucidons la comparaison de nos résultats obtenus et ceux fournis par certains articles traitant des batteries lithium-ion. Il est intéressant de mentionner qu'une approche de fusion basée sur la combinaison de modèles GPR est adoptée dans He et al [17]. Comme on peut l'observer, les stratégies de fusion proposées donnent de meilleurs résultats que les travaux de référence dans presque tous les cas. Il est important de noter que les résultats de prédiction associés à la batterie 18 ne sont pas fournis par les travaux de comparaison.

Dans ce tableau, le codage des approches de fusion IOWA et de sélection est basé sur la notation suivante (Champ1-Champ2), où la première partie désigne la technique adoptée et le second champ représente les fonctions de covariance exploitées.

2.6 Conclusion

Dans ce chapitre, nous avons présenté de nouvelles approches de fusion et de sélection basées sur la régression par processus gaussien et les opérateurs de moyenne pondérée ordonnée induite IOWA. Le schéma de fusion est basé sur la moyenne pondérée des sorties fournies par un ensemble de régresseurs de processus gaussiens en utilisant la méthode IOWA comme outil de fusion. La variance associée aux sorties obtenues fournies par les modèles GPR concurrents est sélectionnée comme ordre inducteur pour l'opérateur IOWA. Dans la méthode de sélection, nous avons choisi parmi les résultats concurrents la valeur ayant la variance la plus faible à chaque instant t . Afin d'améliorer les résultats de la prédiction, une phase supplémentaire de transformation de l'ensemble des données d'apprentissage en valeurs de différence a été proposée dans lequel le signal résultant est susceptible d'être analysé. Tout d'abord, un ensemble de modèles GPR avec différentes fonctions de covariance et d'hyperparamètres lancés aléatoirement a été construit. Dans la deuxième phase, une approche de fusion basée sur la méthode IOWA a été proposée en plus de l'adoption de deux autres techniques de fusion (fusion à base de moyenne et fusion à base d'OWA). La méthode de fusion à base de moyenne a été introduite pour montrer la non-faisabilité de

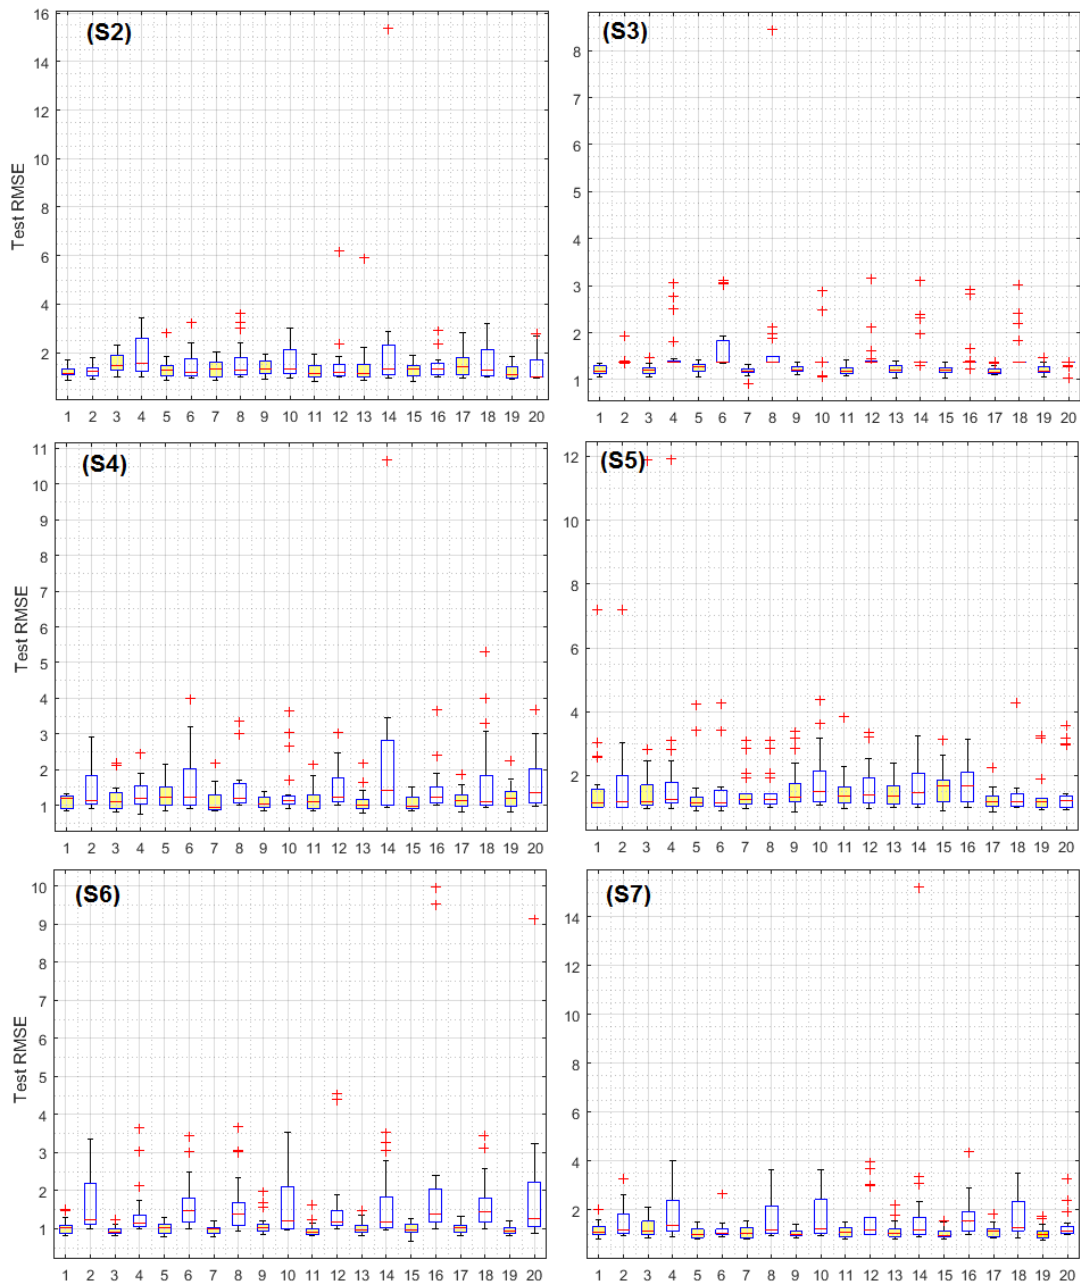


FIGURE 2.14 – Présentation des diagrammes en boîte associés aux valeurs RMSE du test pour chaque sous-ensemble pour les deux techniques

la vision moyenne simple et l'utilité des techniques proposées. Une méthode de sélection a également été introduite pour choisir les valeurs de prédiction avec une variance associée minimale. Différents scénarios ont été considérés afin de valider les approches de fusion et de sélection proposées. Les expériences numériques ont été menées sur le jeu de données des batteries, où les résultats obtenus ont confirmé que les deux approches proposées sont très compétitives en termes d'efficacité et de robustesse.

Dans le chapitre suivant, nous discutons un nouveau cadre de fusion dans lequel la spécification du vecteur de pondération de l'IOWA est traitée en utilisant une stratégie plus élaborée au lieu de leur apprentissage à partir de données.

TABLE 2.7 – Comparaisons des approches proposées et de certains travaux de référence pour les batteries 5, 6, 7 et 18

Ref	Méthode	Batteries			
		Bat 5	Bat 6	Bat 7	Bat 18
Liu et al. [32]	Basic GPR	13.03	22.51	20.70	N/A
	LGPFR	1.71	6.90	1.59	N/A
	QGPFR	1.50	5.12	5.52	N/A
	Combination LGPFR	1.36	6.86	1.73	N/A
	Combination QGPFR	1.80	20.44	2.69	N/A
He et al. [17]	SMK-GPR	1.38	7.08	1.88	N/A
	P-MGPR	1.36	2.12	1.14	N/A
	SE-MGPR	1.20	2.11	1.07	N/A
Qin et al. [33]	Improved PSO-SVR	0.75	1.66	0.97	N/A
Approches proposées	IOWA-SE	0.80	2.24	0.54	4.29
	IOWA-(PER, SE)	1.06	4.19	0.75	4.59
	IOWA-(PER, EYE)	1.11	6.41	0.62	5.31
	IOWA-(PER, NOISE)	1.27	1.30	0.56	4.33
	IOWA-(PER, NN)	1.17	1.43	0.98	2.67
	IOWA-(PER, ULL)	1.08	1.30	0.50	4.11
	IOWA-(PER, Matern)	0.80	1.30	0.81	3.96
	MinVar-SE	0.80	2.24	0.54	4.29
	MinVar-(PER, SE)	1.21	2.61	1.00	3.02
	MinVar-(PER, EYE)	1.37	5.68	1.00	1.73
	MinVar-(PER, NOISE)	1.17	2.71	0.72	3.08
	MinVar-(PER, NN)	1.17	2.71	0.72	4.43
	MinVar-(PER, ULL)	1.22	3.78	0.72	2.72
	MinVar-(PER, Matern)	1.17	2.71	0.72	3.08

N/A : Non Applicable

Références

1. LEI, Y. *et al.* Machinery health prognostics : A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing* **104**, 799-834. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327017305988> (1^{er} mai 2018).
2. MAN, J. & ZHOU, Q. Remaining useful life prediction for hard failures using joint model with extended hazard. *Quality and Reliability Engineering International* **34**, 748-758. ISSN : 1099-1638. <https://onlinelibrary.wiley.com/doi/abs/10.1002/qre.2285> (1^{er} juill. 2018).
3. SHEN, Y., SHEN, L. & XU, W. A Wiener-based degradation model with logistic distributed measurement errors and remaining useful life estimation. *Quality and Reliability Engineering International* **34**, 1289-1303. ISSN : 1099-1638. <https://onlinelibrary.wiley.com/doi/abs/10.1002/qre.2325> (1^{er} oct. 2018).
4. KIM, N.-H., AN, D. & CHOI, J.-H. in *Prognostics and Health Management of Engineering Systems* 1-24 (Springer, Cham, 2017). ISBN : 978-3-319-44740-7 978-3-319-44742-1.
5. JAVED, K., GOURIVEAU, R. & ZERHOUNI, N. 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. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327017300468> (Supplement C 15 sept. 2017).
6. LIAO, L. & KÖTTIG, F. 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**, 191-207. ISSN : 0018-9529 (mars 2014).
 7. ELATTAR, H. M., ELMINIR, H. K. & RIAD, A. M. Prognostics : a literature review. *Complex & Intelligent Systems* **2**, 125-154. ISSN : 2199-4536, 2198-6053. <https://link.springer.com/article/10.1007/s40747-016-0019-3> (1^{er} juin 2016).
 8. AHMADZADEH, F. & LUNDBERG, J. Remaining useful life estimation : review. *International Journal of System Assurance Engineering and Management* **5**, 461-474. ISSN : 0975-6809, 0976-4348. <https://link.springer.com/article/10.1007/s13198-013-0195-0> (1^{er} déc. 2014).
 9. YAGER, R. & FILEV, D. P. Induced ordered weighted averaging operators. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)* **29**, 141-150. ISSN : 1083-4419 (avr. 1999).
 10. FILEV, D. & YAGER, R. Learning OWA operator weights from data in *Proceedings of 1994 IEEE 3rd International Fuzzy Systems Conference Proceedings of 1994 IEEE 3rd International Fuzzy Systems Conference* (juin 1994), 468-473 vol.1.
 11. FILEV, D. & YAGER, R. On the issue of obtaining OWA operator weights. *Fuzzy Sets and Systems* **94**, 157-169. ISSN : 0165-0114. <http://www.sciencedirect.com/science/article/pii/S0165011496002540> (1^{er} mars 1998).
 12. HU, C., YOUN, B. D., WANG, P. & TAEK YOON, J. Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life. *Reliability Engineering & System Safety* **103**, 120-135. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S0951832012000427> (1^{er} juill. 2012).
 13. XU, J., WANG, Y. & XU, L. PHM-Oriented Integrated Fusion Prognostics for Aircraft Engines Based on Sensor Data. *IEEE Sensors Journal* **14**, 1124-1132. ISSN : 1530-437X (avr. 2014).
 14. SBARUFATTI, C., CORBETTA, M., MANES, A. & GIGLIO, M. Sequential Monte-Carlo sampling based on a committee of artificial neural networks for posterior state estimation and residual lifetime prediction. *International Journal of Fatigue* **83**, 10-23. ISSN : 0142-1123. <https://www.sciencedirect.com/science/article/pii/S0142112315001747> (1^{er} fév. 2016).
 15. LIU, Y., ZHAO, G., PENG, X. & LIU, Y. A fusion prognostic approach based on multi-kernel relevance vector machine and Bayesian model averaging in *2016 Prognostics and System Health Management Conference (PHM-Chengdu) 2016 Prognostics and System Health Management Conference (PHM-Chengdu)* (oct. 2016), 1-6.
 16. DU, S., LV, J. & XI, L. Degradation process prediction for rotational machinery based on hybrid intelligent model. *Robotics and Computer-Integrated Manufacturing* **28**, 190-207. ISSN : 0736-5845. <http://www.sciencedirect.com/science/article/pii/S0736584511001086> (1^{er} avr. 2012).
 17. HE, Y.-J., SHEN, J.-N., SHEN, J.-F. & MA, Z.-F. State of health estimation of lithium-ion batteries : A multiscale Gaussian process regression modeling approach. *American Institute of Chemical Engineers Journal* **61**, 1589-1600. ISSN : 1547-5905. <http://onlinelibrary.wiley.com/doi/10.1002/aic.14760/abstract> (1^{er} mai 2015).

18. YAGER, R. On ordered weighted averaging aggregation operators in multicriteria decision making. *IEEE Trans. Syst., Man, Cybern* **18**, 183-190. ISSN : 0018-9472 (jan. 1988).
19. YAGER, R., KACPRZYK, J. & BELIAKOV, G. *Recent Developments in the Ordered Weighted Averaging Operators : Theory and Practice* réd. par KACPRZYK, J. ISBN : 978-3-642-17909-9 978-3-642-17910-5. <http://link.springer.com/10.1007/978-3-642-17910-5> (Springer Berlin Heidelberg, Berlin, Heidelberg, 2011).
20. ALHICHRI, H. *et al.* A novel fusion approach based on induced ordered weighted averaging operators for chemometric data analysis. *Journal of Chemometrics* **27**, 447-456. ISSN : 0886-9383. <https://onlinelibrary.wiley.com/doi/full/10.1002/cem.2557> (8 déc. 2013).
21. BAZI, Y., ALAJLAN, N., MELGANI, F., ALHICHRI, H. & YAGER, R. Robust Estimation of Water Chlorophyll Concentrations With Gaussian Process Regression and IOWA Aggregation Operators. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **7**, 3019-3028. ISSN : 1939-1404 (juill. 2014).
22. YAGER, R. Soft Aggregation Methods in Case Based Reasoning. *Applied Intelligence* **21**, 277-288. ISSN : 1573-7497. <https://doi.org/10.1023/B:APIN.0000043560.57137.20> (1^{er} nov. 2004).
23. RASMUSSEN, C. E. & WILLIAMS, C. K. I. *Gaussian Processes for Machine Learning* <http://www.gaussianprocess.org/gpml/chapters/RW.pdf> (The MIT Press Cambridge MA, 2006).
24. AN, D., KIM, N. H. & CHOI, J.-H. Practical options for selecting data-driven or physics-based prognostics algorithms with reviews. *Reliability Engineering & System Safety* **133**, 223-236. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S0951832014002245> (Supplement C 1^{er} jan. 2015).
25. WILLIAMS, C. K. I. & RASMUSSEN, C. E. *Gaussian processes for regression in In Advances in Neural Information Processing Systems 8* (MIT Press, 1996). <http://papers.nips.cc/paper/1048-gaussian-processes-for-regression.pdf>.
26. AN, D. & CHOI, J. H. Efficient reliability analysis based on Bayesian framework under input variable and metamodel uncertainties. *Structural and Multidisciplinary Optimization* **46**, 533-547. ISSN : 1615-147X, 1615-1488. <https://link.springer.com/article/10.1007/s00158-012-0776-6> (1^{er} oct. 2012).
27. YAGER, R. Families of OWA operators. *Fuzzy Sets and Systems* **59**, 125-148. ISSN : 0165-0114. <http://www.sciencedirect.com/science/article/pii/016501149390194M> (25 oct. 1993).
28. YAGER, R. Generalized OWA Aggregation Operators. *Fuzzy Optimization and Decision Making* **3**, 93-107. ISSN : 1568-4539, 1573-2908. <https://link.springer.com/article/10.1023/B:FODM.0000013074.68765.97> (1^{er} mars 2004).
29. MERIGÓ, J. M. & GIL-LAFUENTE, A. M. The induced generalized OWA operator. *Information Sciences* **179**, 729-741. ISSN : 0020-0255. <http://www.sciencedirect.com/science/article/pii/S002002550800488X> (1^{er} mars 2009).
30. MCCUNE, B. & GRACE, J. *Analysis of Ecological Communities* ISBN : 978-0-9721290-0-8 (Mjm Software Design, Gleneden Beach, Or, 2002).
31. SAHA, B. & GOEBEL, K. *Battery data set, NASA ames prognostics data repository*. NASA Ames 2007. <http://ti.arc.nasa.gov/project/%20prognostic-data-repository>.

32. LIU, D., PANG, J., ZHOU, J., PENG, Y. & PECHT, M. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression. *Microelectronics Reliability* **53**, 832-839. ISSN : 0026-2714. <http://www.sciencedirect.com/science/article/pii/S0026271413000747> (1^{er} juin 2013).
33. QIN, T., ZENG, S. & GUO, J. Robust prognostics for state of health estimation of lithium-ion batteries based on an improved PSO–SVR model. *Microelectronics Reliability* **55**, 1280-1284. ISSN : 0026-2714. <http://www.sciencedirect.com/science/article/pii/S0026271415300792> (1^{er} août 2015).

Chapitre 3

Nouveaux cadres hybrides de pronostic à base des fonctions de pondération explicites

Résumé : Le présent chapitre est consacré à l'étude de trois nouveaux schémas de fusion pour la prévision de la durée de vie utile restante. Ces cadres intégrés sont basés sur l'agrégation d'un ensemble de modèles de régression à processus gaussien grâce aux opérateurs de moyenne pondérée ordonnée induite. La procédure de combinaison repose sur trois schémas de pondération analytiques proposés, notamment les fonctions exponentielle, logarithmique et inverse. En outre, l'aspect de l'incertitude est pris en charge dans ce travail, où les fonctions proposées sont utilisées pour réaliser la moyenne pondérée des variances fournies par les modèles de régression de processus gaussiens compétitifs. Les données d'apprentissage sont transformées en valeurs de gradient, qui sont adoptées comme nouvelles données d'apprentissage au lieu des observations originales. Un ensemble de données des batteries lithium-ion est utilisé comme référence pour prouver l'efficacité des schémas de pondération proposés. Les résultats obtenus sont prometteurs et peuvent fournir quelques lignes directrices pour les progrès futurs concernant l'estimation précise de la durée de vie utile restante.

3.1 Introduction

Le pronostic et la gestion de l'état (PHM) des systèmes a récemment prospéré comme une nouvelle discipline dans de nombreux domaines. Ceci a permis d'évaluer l'état des systèmes industriels en utilisant diverses techniques telles que les modèles physiques, l'ingénierie de la fiabilité et les techniques d'apprentissage automatique. Sur la base des conditions de fonctionnement réelles, des données fournies et de l'état de système, la stratégie PHM facilite l'obtention d'informations pertinentes et utiles pour maintenir le système dans un régime souhaité [1]. Parmi les tâches principales de PHM, nous trouvons le pronostic de la durée de vie utile restante (RUL) utilisant les données observées pour la prédiction du comportement de dégradation futur du système [2, 3]. En général, le pronostic de la durée de vie utile restante peut être accompli en se basant sur trois approches clés reconnues, à savoir les techniques basées sur un modèle physique, les techniques basées sur les données et les techniques hybrides [4-6]. Pour le pronostic basé sur un modèle physique, la connaissance du comportement de dégradation du système est importante. Cependant, les techniques orientées données sont plus privilégiées en cas de compréhension restrictive ou non disponibilité d'un point de vue physique. Afin de remédier aux inconvénients inhérentes à chaque classe, des approches hybrides ont été développées pour profiter des avantages de chaque classe [7]. Dans le cadre des approches hybrides, une procédure de fusion peut être réalisée en combinant plusieurs méthodes coopératives. Une telle combinaison est classée en deux types, le premier utilise un modèle pour prédire l'état du système conjointement avec une autre méthode sélectionnée pour estimer le RUL. Le deuxième type de combinaison se concentre sur l'agrégation des résultats fournis par différentes approches en utilisant une technique de fusion adéquate [8, 9]. Il est primordial de mentionner que l'incertitude est un facteur important qui est inévitable dans le pronostic de RUL et c'est pourquoi l'utilisation de plusieurs stratégies de traitement est recommandée. Par exemple, éviter le surajustement, gérer le bruit et combiner les modèles peuvent être adoptés comme solutions pour diminuer le niveau d'incertitude pendant les opérations de pronostic [10].

Dans ce contexte, le présent chapitre est consacré à l'élaboration d'un nouveau cadre de fusion afin de remédier à nombreux inconvénients et couvrir certains aspects qui, à notre connaissance, n'ont pas été traités d'une façon efficace dans la littérature disponible. La stratégie de combinaison est construite en se basant sur une méthode de classement et un ensemble de prédicteurs, où les poids sont exprimés par des fonctions analytiques explicites.

Par ailleurs la section 3.2 est consacrée à la présentation de quelques travaux connexes et illustre les caractéristiques principales associées aux modèles de pronostic. La section 3.3 présente le contexte des techniques adoptées, à savoir l'estimation basée sur le processus gaussien et la méthode de moyenne pondérée ordonnée induite (IOWA). Dans la section 3.4, nous présentons en détail l'approche proposée, y compris les trois fonctions de pondération analytiques introduites. Nous discutons les résultats expérimentaux dans la section 3.5, où des expériences de simulation intensives sont menées, tout en soulignant les avantages principaux et les limites de l'approche proposée. Enfin, nous terminons le chapitre par quelques conclusions et futures extensions.

3.2 Etat de l'art

Malgré la disponibilité de nombreux travaux publiés traitant du développement de systèmes de pronostic, il est à souligner que la littérature concernant l'application de techniques de fusion est limitée [11] et en particulier l'étude de l'opérateur IOWA comme outil de fusion [12]. Parmi les approches de fusion basées sur l'agrégation des résultats, Gebraeel et al. ont exploité les informations vibratoires collectées lors d'essais accélérés de roulements, pour former un ensemble de modèles de réseaux neuronaux à rétro-propagation, qui sont adoptés pour estimer le temps de fonctionnement des roulements [13]. Un exemple de pondération basé sur les divergences entre les temps de fonctionnement réels et prédits est adopté pour agréger les résultats fournis par les réseaux de neurones dans le but d'estimer le RUL. Les auteurs dans [14] ont introduit un modèle de fusion basé sur deux approches différentes pour les données collectées à partir de roulements avioniques de type "run-to-failure". La combinaison est obtenue par l'agrégation des résultats délivrés en appliquant une méthode à base de modèle physique basée sur le modèle de propagation des défauts et l'approche de pronostic basée sur l'expérience. Dans [15], trois approches de pronostic sont agrégées sur un modèle de prévision de combinaison linéaire optimale pour une évaluation de l'état d'un système avionique. L'approche proposée à opter pour la combinaison des stratégies basées sur les modèles, les données et les connaissances. Un calcul dynamique des poids de sous-modèles basé sur l'analyse de similarité floue (FSA) est établi pour agréger un ensemble de regresseurs de type vecteur à support probabiliste [16]. L'approche proposée est prouvée et évaluée en utilisant la pompe de refroidissement du réacteur (RCP) d'une étude de cas de réacteur nucléaire de type PWR. Les auteurs dans [17] ont introduit une méthode de pronostic basée sur l'apprentissage de données pour prédire le RUL des moteurs d'avion. Les poids optimaux alloués à chaque modèle sont obtenus en utilisant les techniques d'optimisation par essaims de particules (PSO) et d'optimisation quadratique séquentielle (SQP). Dans [18], une nouvelle méthode hybride de pronostic a été proposée pour estimer le RUL en fonction de pondération. L'approche proposée attribue un poids optimisé dépendant de la dégradation à chaque algorithme de pronostic et additionne de manière pondérée les sorties obtenues pour estimer la durée de vie utile finale. Une approche de moyenne pondérée est adoptée dans [19] pour fusionner un ensemble de modèles CNN-BLSTM (Convolutional Bi-directional Long Short-Term Memory) avec différentes tailles de fenêtres temporelles. Le cadre proposé est validé en utilisant le jeu de données C-MAPSS (Commercial Modular Aero-Propulsion System Simulation) de NASA. Les auteurs en [20] ont combiné un ensemble d'algorithmes de pronostic, notamment la fonction de base radiale (RBF), la machine à vecteur de support (SVM), le modèle gris (GM) et le modèle ARIMA (Autoregressive Integrated Moving Average). Cette stratégie de fusion a été proposée dans le but de prédire la capacité de la batterie en utilisant la méthode IOWA comme outil d'agrégation. Une approche de fusion basée sur la régression par processus gaussien et les opérateurs IOWA a été présentée dans un travail récent [12] pour la prédiction de la durée de vie utile restante. La méthode IOWA est utilisée pour agréger les résultats générés par une collection d'estimateurs GPR.

Dans ce travail, la technique IOWA est exploitée avec une approche de descente de gradient pour apprendre les éléments du vecteur de pondération utilisés dans l'agrégation à partir des données d'apprentissage observées. Afin d'offrir au lecteur une vue d'ensemble des principaux travaux connexes, nous résumons dans le tableau 3.1 certaines caractéristiques à respecter par un modèle efficace de pronostic, où les lignes correspondent aux travaux antérieurs les plus similaires, et les colonnes représentent les caractéristiques souhaitées.

TABLE 3.1 – Résumé des travaux connexes par rapport aux caractéristiques de pronostic souhaitées

Ref	Techniques adoptées	Précision	Généralisation	Prise en charge de l'incertitude	Coût en temps	Calcul des poids
[13]	NN	Une grande précision en considérant la fusion par rapport à un modèle simple	Nécessité de disposer de données satisfaisantes	Non considérée	Non fourni	Basé sur l'erreur d'apprentissage
[14]	Modèle basé sur la physique et sur l'expérience	Une grande précision en considérant la fusion par rapport à un modèle simple	Nécessité d'un modèle physique des roulements et de données historiques	Méthode de régression Dempster-Shafer	Non fourni	Basé sur la moyenne pondérée et ANFIS
[15]	ARMA, SVM et FNN	Une grande précision en considérant la fusion par rapport à un modèle simple	Nécessité de données historiques	Non considérée	Non fourni	Basé sur la résolution d'un problème de programmation linéaire
[16]	FSA, SVR et RBF	Une grande précision en considérant la fusion par rapport à un modèle simple	Nécessité de données de forme de séries temporelles	Méthode d'agrégation	Non fourni	Basé sur le FSA
[17]	RFs, CART, RNN, AR, ANFIS, RVM, and EN	Une grande précision en considérant la fusion par rapport à un modèle simple et quelques travaux connexes	Nécessité de disposer de données historiques satisfaisantes	Non considérée	Non fourni	Basé sur les méthodes PSO et SQP
[18]	Cas1 : BI, RVM, RS et PF, Cas2 : RS, SS, ES, QB et RNN	Une grande précision en considérant la fusion par rapport à un modèle simple et quelques travaux connexes	Nécessité de disposer de données historiques satisfaisantes et d'un modèle physique	Non considérée	Non fourni	Basé sur une optimisation à chaque étape de la dégradation
[19]	CNN-BLSTM	Une grande précision en considérant la fusion par rapport à un modèle simple et quelques travaux connexes	Nécessité de disposer de données historiques de grande taille	Non considérée	Non fourni	Basé sur l'erreur d'apprentissage
[20]	RBS, VM, GM et ARMA	Une grande précision en considérant la fusion par rapport à un modèle simple	Nécessité de données historiques	Non considérée	Non fourni	Basé sur la méthode V-IOWA
[12]	GPR et IOWA	Une grande précision en considérant la fusion par rapport à un modèle simple et quelques travaux connexes	Nécessité de données historiques	Possibilité d'estimation en utilisant la variance	Analyse de la consommation de temps	Basé sur les opérateurs IOWA

Une évaluation vigilante de ce tableau permet de révéler quelques observations critiques, notamment la consommation de temps qui n'est pas considéré conjointement avec la précision des résultats malgré son importance primordiale. De plus, presque tous les travaux sont basés sur la spécification des poids en utilisant des méthodes gourmandes en temps de calcul, ce qui entraîne des charges de calcul supplémentaires. On peut également

reconnaître que la gestion de l'incertitude n'est pas prise en compte dans de nombreux travaux connexes. À notre connaissance, il n'existe pas d'approche de fusion à base de IOWA fondée sur des formulations analytiques explicites des facteurs de pondération. Notre objectif est donc d'introduire un nouveau schéma de fusion basé sur des modèles de régression à processus gaussien et des opérateurs IOWA, dans lequel le processus de pondération est réalisé par trois fonctions analytiques proposées, à savoir les fonctions exponentielle, logarithmique et inverse. Une étape préliminaire, qui est la transformation des données observées en valeurs de gradient, est accréditée et utilisée au lieu des données originales car de nombreux avantages peuvent être obtenus en appliquant cette classe de transformations [12]. De plus, l'incertitude est contrôlée dans notre cadre en fournissant des bornes de confiance à 95% grâce à la moyenne pondérée des variances issues des estimateurs GPR en utilisant les fonctions proposées.

3.3 Contexte théorique

Dans ce qui suit, nous présentons les principaux aspects liés aux différents outils étudiés dans le contexte de la fusion proposé.

3.3.1 Estimation basée sur un processus gaussien

Un processus gaussien est considéré comme étant un processus stochastique généralisant la distribution de probabilité gaussienne. La distribution de probabilité fait référence à des variables aléatoires définies par des scalaires ou des vecteurs, tandis que le processus gaussien est un processus stochastique contrôlant les caractéristiques des fonctions. Le processus gaussien a été défini par Rasmussen comme une collection de variables aléatoires comprenant un nombre fini avec une distribution gaussienne associée [21]. Par conséquent, la définition suivante est fournie :

Définition 1 *Un processus gaussien est une collection de variables aléatoires comprenant un nombre fini avec une distribution gaussienne commune.*

Mathématiquement, comme une distribution gaussienne est déterminée par un vecteur de moyenne et une matrice de covariance, un GP peut également être décrit par une fonction de moyenne $m(x)$ et un noyau $k(x, x')$ appelé fonction de covariance. Les fonctions de moyenne et de covariance pour un processus réel sont définies respectivement par les équation 3.1 et 3.2 :

$$m(x) = E[f(x)] \quad (3.1)$$

et

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (3.2)$$

où le processus gaussien est exprimé comme :

$$f(x) \sim GP(m(x), k(x, x')) \quad (3.3)$$

La composante très importante d'un GP est sa partie covariance, qui code les hypothèses de l'utilisateur pendant la procédure de modélisation d'un comportement inconnu. La cartographie de la covariance $k(x, x')$ peut être assimilée à une distance entre les points d'entrée x et x' . Pour la modélisation de tout système, la fonction de covariance englobe généralement deux termes principaux comme indiqué dans l'équation 3.4 :

$$k(x, x') = k_f(x, x') + k_n(x, x') \quad (3.4)$$

où k_f et k_n désignent respectivement la partie fonctionnelle (décrivant le système inconnu modélisé) et la partie bruit (décrivant le modèle de bruit) [22]. Les performances d'un modèle GPR dépendent du choix de la fonction de covariance, de manière similaire aux réseaux neuronaux, pour lesquels la fonction d'activation peut influencer les résultats [23].

Pour un problème de régression donné par $y = f(x) + \epsilon$, la représentation du GP peut être interprétée comme la superposition de la fonction linéaire latente $f(x)$ et d'un bruit blanc gaussien additif ϵ . La distribution antérieure de y s'écrit :

$$\text{Cov}(y) = K(X, X) + \sigma_{ns}^2 I \quad (3.5)$$

tandis que la distribution conjointe antérieure d'une cible fournie y et d'une observation de test estimée f_* est formulée comme indiqué par l'équation 3.6 :

$$\begin{bmatrix} y \\ f_* \end{bmatrix} \sim N \left(\begin{bmatrix} m(X) \\ m(X_*) \end{bmatrix}, \begin{bmatrix} K(X, X) + \sigma_{ns}^2 I & K(X, X_*) \\ K(X_*, X) & K(X_*, X_*) \end{bmatrix} \right) \quad (3.6)$$

où $m(x)$ représente la fonction moyenne, K désigne la matrice de covariance du processus gaussien, X désigne les données d'apprentissage et X_* représente les données de test. Les paramètres σ_{ns}^2 et I indiquent la variance du bruit et la matrice d'identité, respectivement. La sortie de test f_* est déduite de la distribution postérieure en utilisant l'expression prédictive du processus gaussien pour la régression :

$$f_* | X, y, X_* \sim N(\bar{f}_*, \text{cov}(f_*)), \quad (3.7)$$

avec

$$\bar{f}_* = m(X_*) + K(X_*, X)[K(X, X) + \sigma_{ns}^2 I]^{-1}(y - m(X))$$

et

$$\text{cov}(f_*) = K(X_*, X_*) - K(X_*, X)[K(X, X) + \sigma_{ns}^2 I]^{-1}K(X, X_*)$$

où $m(X)$ et $m(X_*)$ sont respectivement les moyennes des données d'apprentissage et de données de test.

Le problème de l'apprentissage dans le processus gaussien est équivalent à déterminer les paramètres appropriés de la fonction de covariance. Ceci est afin de prendre en charge certaines caractéristiques du comportement des données utiles pour l'interprétation. Ces paramètres libres présents dans les termes de moyenne et de covariance sont connus sous le nom d'hyperparamètres, qui sont ajustés à l'aide des données d'apprentissage en optimisant le critère de vraisemblance marginale. Cet objectif est réalisé par marginalisation sur la fonction latente, comme décrit par l'équation 3.8

$$\log(y|X, \theta) = -\frac{1}{2}y^T(K + \sigma_{ns}^2 I)^{-1}y - \frac{1}{2}\log(|K + \sigma_{ns}^2 I|) - \frac{nt}{2}\log(2\pi) \quad (3.8)$$

où θ et I représentent respectivement le vecteur des hyperparamètres et la matrice unitaire, tandis que nt désigne la taille de l'ensemble de données d'apprentissage. Une technique de recherche basée sur le gradient est utilisée pour obtenir la solution approximative de ce problème de maximisation [21]. Comme la fonction de vraisemblance de nombreux noyaux n'est pas convexe par rapport aux hyperparamètres, les valeurs obtenues associées à ces paramètres ne correspondent pas toujours à un optimum global et la procédure d'optimisation peut converger vers une solution locale. Pour remédier à cet inconvénient, de nombreux chercheurs exécutent la procédure d'optimisation plusieurs fois en utilisant différentes initialisations pour les hyperparamètres, où les valeurs choisies sont basées sur l'expérience de l'utilisateur [23]. Pour contourner l'initialisation inappropriée des hyperparamètres ou le mauvais choix d'une fonction de covariance, la fusion de différents modèles peut conduire à des meilleures solutions. L'approche de fusion IOWA peut être considérée comme un candidat puissant pour accomplir une telle tâche.

3.3.2 Aperçu sur la méthode IOWA

L'opérateur de moyenne pondérée ordonnée (OWA) peut être vu comme une famille de structures de combinaison moyennes avec des paramètres ajustables [24]. Une étape supplémentaire importante dans l'opérateur OWA, qui est la phase de classement des arguments par leurs valeurs, le rend non linéaire. Dans ce contexte, Yager a défini mathématiquement l'opérateur OWA de dimension n par :

Définition 2 Soit $F : R^n \rightarrow R^n$ une application multi-valuée. L'opérateur OWA représenté par $W = [w_j, j = 1..n]^T$ est un vecteur de pondération affecté à F et satisfait les contraintes suivantes :

$$w_j \in [0, 1] \quad (3.9)$$

$$\sum_{j=1}^n w_j = 1 \quad (3.10)$$

et

$$F(a_1, a_2, \dots, a_n) = \sum_{j=1}^n w_j b_j \quad (3.11)$$

avec b_j lié à la $j^{\text{ème}}$ plus grande composante a_i . L'étape clé de cet opérateur concerne le réarrangement des arguments en fonction de leurs valeurs. Dans la moyenne pondérée standard, les poids sont associés à des arguments spécifiques, alors que les poids dans OWA sont affectés à des positions particulières dans l'ordre. On peut remarquer qu'une telle réorganisation ajoute de la non-linéarité pour un processus linéaire. L'agrégation basée sur les opérateurs OWA/IOWA satisfait les propriétés usuelles à savoir la monotonie, la commutativité, l'idempotence et la limitation ($\text{Min}(a_i) \leq (a_1, a_2, \dots, a_n) \leq \text{Max}(a_i)$) comme démontré dans [25]. Les opérateurs Min, Max et Moyenne peuvent être considérés comme des exemples particuliers d'OWA en sélectionnant les vecteurs de pondération suivants pour W : $W = [1/n, 1/n, \dots, 1/n]^T$, $W = [1, 0, 0, \dots, 0]^T$ et $W = [0, 0, \dots, 0, 1]^T$ respectivement.

Un nouveau type d'opérateur OWA a été proposé par Yager dans [25] appelé opérateur de moyenne pondérée ordonnée induite, qui se distingue de la méthode OWA typique dans la phase de réarrangement. En effet, les arguments sont triés selon un facteur auxiliaire appelé élément inducteur dans l'approche IOWA. Le processus de calcul de la combinaison IOWA de ces paires est donné par l'équation 3.12

$$F(\langle u_1, a_1 \rangle, \dots, \langle u_n, a_n \rangle) = \sum_{j=1}^n w_j b_j \quad (3.12)$$

où b_j est la valeur a de la paire IOWA ayant la $j^{\text{ème}}$ plus grande valeur u . Le lecteur peut trouver plus de classes d'opérateurs OWA dans les références [26-28] et [29].

Le processus d'agrégation basé sur l'opérateur IOWA offre une plus grande souplesse par rapport aux cas extrêmes d'agrégation identifiés par "et" et "ou", où le degré de "et" et de "ou" dans la procédure de combinaison est implicitement ajusté par la méthode IOWA [24]. Yager a introduit deux mesures pour exprimer le niveau de "et" et de "ou" en plus de la quantité d'information dans les arguments lorsque la combinaison utilisant le vecteur de pondération W est réalisée. Les deux mesures appelées Orness et Dispersion sont données respectivement par [25] :

$$\text{Orness}(W) = \frac{1}{n-1} \sum_{i=1}^n (n-i)w_i \quad (3.13)$$

et

$$\text{Disp}(W) = \sum_{i=1}^n w_i \ln(w_i) \quad (3.14)$$

Le principal défi des procédures OWA et IOWA concerne la spécification du vecteur de pondération W . Depuis les premières propositions de l'approche IOWA, plusieurs paradigmes ont été proposés pour générer le vecteur de pondération [30-32].

3.4 Schéma de pondération proposé

Dans ce travail, nous présentons une nouvelle approche de fusion basée sur les modèles de régression par processus gaussiens et les opérateurs IOWA. La technique de fusion est mise en œuvre sur la base de l'agrégation des sorties des GPRs en utilisant la méthode IOWA

à travers trois schémas de pondération proposés : les fonctions exponentielle, logarithmique et inverse.

Premièrement, soit $Y = \{t, f(t)\}_{t=1}^{ntrain}$ indique les observations d'apprentissage où l'indice de temps t est lié à des données avec une longueur $ntrain$, $f(t) = y_t$ est lié aux valeurs observées des données disponibles, qui représentent le comportement de dégradation dans le système reflétant l'indicateur d'état du processus. La variable t fait référence au vecteur d'entrée et y_t est le vecteur de sortie.

Étant donné l'ensemble d'apprentissage Y et afin de prédire avec précision la durée de vie utile restante, ceci peut être facilité en estimant la progression de la dégradation pour les cycles suivants $t = ntrain + 1, ntrain + 2, \dots, ntrain + ntest$. Un ensemble de n estimateurs GPR différents est développé et utilisé pour atteindre cet objectif.

Afin d'améliorer les performances de prédiction, les résultats de ces estimateurs sont agrégés en introduisant trois approches de fusion par le biais de procédures de pondération distinctes proposées. La première est la pondération exponentielle, la seconde est la pondération logarithmique et enfin la pondération basée sur la fonction inverse.

Les étapes principales de notre cadre de fusion proposé sont illustrées sur la figure 3.1. Une description complète de chaque étape est alors fournie.

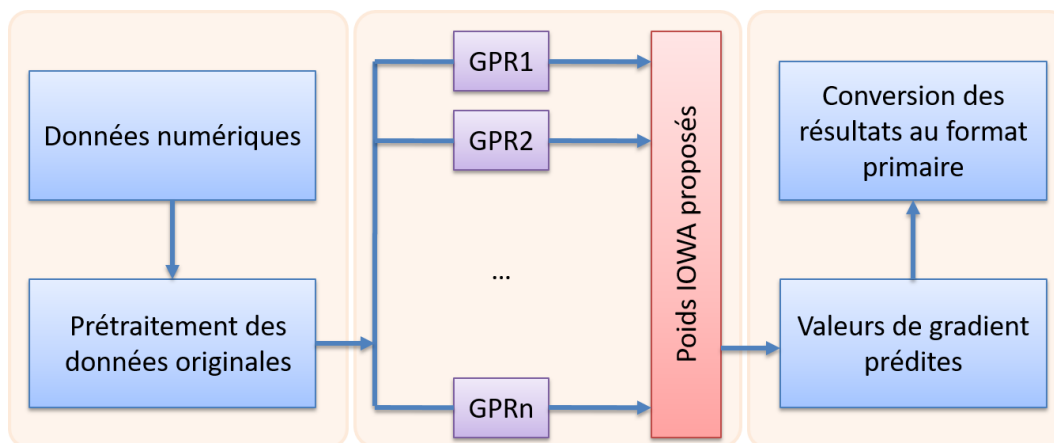


FIGURE 3.1 – Visualisation des étapes principales du cadre de fusion proposé

3.4.1 Prétraitement des données originales

La transformation des données observées sous une forme plus appropriée peut offrir différents avantages pour l'exploitation, notamment l'homogénéité et la normalité des données. Une telle transformation peut être réalisée de différentes manières, par exemple par des transformations en puissance ou en *arcsinus*. Pour les données en séries temporelles, la prise en compte de l'écart entre les dates successives au lieu des signaux originaux acquis peut être très utile pour la procédure de prédiction. Dans ce travail, la transformation en gradients est appliquée aux données observées de façon à ce que l'information soit plus facile à étudier et que les caractéristiques pertinentes des données soient préservées. Plus de détails concernant la transformation en gradients ainsi que son application sont fournis dans la référence [12].

3.4.2 Élaboration des modèles GPR

A ce niveau, un ensemble de n modèles GPR est développé et appliqué pour réaliser le processus de prédiction. Chaque régresseur GPR est déterminé par sa fonction de covariance appropriée et ses hyperparamètres initiaux. Les sorties fournies par les différents estimateurs GPR sont utilisées comme entrée pour l'étape suivante, où elles sont agrégées en utilisant les fonctions de pondération proposés.

3.4.2.1 Fusion avec les opérateurs IOWA

Considérons $\langle p_{tj}, v_{tj} \rangle = GPR_j(t)$ où p_{tj} représente la sortie de prédiction et v_{tj} la variance associée fournie par le $j^{\text{ème}}$ régresseur GPR au temps t .

Afin d'agréger les sorties des GP délivrées en utilisant les opérateurs de fusion IOWA, il est nécessaire de construire le vecteur B des arguments classés. Une notation vectorielle de l'opérateur de fusion IOWA est donnée par l'équation 3.15 :

$$F(p_{t1}, p_{t2}, \dots, p_{tn}) = W^T B \quad (3.15)$$

où F et W sont respectivement l'opérateur de fusion et le vecteur de pondération de la méthode IOWA. p_{tj} représente les arguments agrégés. Le vecteur B représente le vecteur des arguments classés, où ses éléments sont triés par la variance négative correspondante $-v_{tj}$, considérée comme la valeur inductrice choisie. Les éléments de B sont classés par ordre décroissant, où une plus grande importance est consacrée aux valeurs prédites p_{tj} ayant une variance minimale.

3.4.2.2 Détermination des poids

L'étape cruciale dans une large classe d'applications est l'obtention du vecteur de pondération W . Dans la littérature, plusieurs approches ont été développées pour la définition du vecteur de pondération, notamment les méthodes basées sur les arguments, l'optimisation et l'apprentissage à partir de données [31]. L'idée de cette dernière technique est d'apprendre les poids à partir des données d'apprentissage observées en utilisant une procédure d'optimisation telle que la méthode de descente de gradient décrite et appliquée dans [12, 33].

Maintenant, nous devons calculer le vecteur de pondération $W = [w_1, w_2, \dots, w_n]^T$ sous la condition :

$$W^T B_t = d_t |_{t=1:ntrain-1} \quad (3.16)$$

où $B_t = [b_{t1}, b_{t2}, \dots, b_{tn}]$ reflète le vecteur ordonné des valeurs prédites $(p_{t1}, p_{t2}, \dots, p_{tn})$ délivrées par les modèles GPR_j , et d_t signifie la sortie cible.

Les composantes du vecteur de pondération W sont en accord avec les contraintes de l'approche IOWA 3.9 et 3.10, où elles peuvent être extraites par l'optimisation des erreurs instantanées e_t données par l'équation 3.17

$$e_t = \frac{1}{2}(b_{t1}w_1 + b_{t2}w_2 + \dots + b_{tn}w_n - d_t)^2 \quad (3.17)$$

La satisfaction des contraintes 3.9 et 3.10 en plus aux erreurs et donne lieu à un problème d'optimisation sous contraintes. Pour faire face aux contraintes imposées, Yager a proposé une transformation des poids sous la forme suivante :

$$w_i = \frac{e^{\lambda_i}}{\sum_{j=1}^n e^{\lambda_j}}, i = 1 : n \quad (3.18)$$

avec λ joue le rôle d'un paramètre auxiliaire.

L'adoption d'une telle modification permet de normaliser les poids dans l'intervalle $[0 : 1]$ avec une somme égale à 1. Ainsi, le problème d'apprentissage ci-dessus se réduit à un problème de programmation non linéaire sans contraintes. La méthode de descente du gradient a été largement adoptée pour résoudre ce type de problème, comme illustré dans [31, 33].

Au lieu de leur apprentissage à partir des données, nous proposons dans ce travail un nouveau vecteur de pondération W utilisant la variance associée autour de chaque valeur prédite.

Le vecteur $B_t = [b_{t1}, b_{t2}, \dots, b_{tn}]$ contient les valeurs triées de la sortie $(p_{t1}, p_{t2}, \dots, p_{tn})$ issue des n estimateurs GPR. Afin d'attribuer un poids significatif à la valeur dotée d'une variance minimale, nous proposons ces trois vecteurs de pondération pour chaque temps t :

$$w_i^{exp} = \frac{e^{-v_{ti}}}{\sum_{j=1}^n e^{-v_{tj}}}, i = 1 : n \quad (3.19)$$

$$w_i^{log} = \frac{\log(1/v_{ti})}{\sum_{j=1}^n \log(1/v_{tj})}, i = 1 : n \quad (3.20)$$

$$w_i^{inv} = \frac{1/v_{ti}}{\sum_{j=1}^n 1/v_{tj}}, i = 1 : n \quad (3.21)$$

Contrairement aux procédures de pondération classiques où le même vecteur est conservé dans l'agrégation pour tous les instants, un vecteur actualisé est attribué à chaque instant dans notre travail. Les méthodes de pondération proposées satisfont aux deux conditions 3.9 et 3.10, qui sont nécessaires dans le contexte du cadre de la méthode IOWA. En outre, des poids élevés sont associés aux éléments ayant de petites variances et les valeurs prédites sont classées par ordre décroissant de la valeur inductrice (ordre croissant de la variance). Cet ordre décroissant dans le vecteur B implique un ordre décroissant dans les poids associés. La tendance décroissante en plus des conditions 3.9 et 3.10 est respectée pour n'importe quelle valeur de la variance pour tous les vecteurs de pondération proposés, sauf pour la fonction logarithmique, où les valeurs v_i doivent être comprises dans la plage $[0 : 1]$, et $v_i \neq 0$ pour la pondération inverse et logarithmique. Pour assurer un ordre décroissant dans la pondération logarithmique, une procédure de normalisation entre 0, 1 et 0, 9 est adoptée pour toutes les fonctions de pondération en termes de variance.

Dans la figure 3.2, nous représentons les valeurs de pondération obtenues par l'application des trois approches proposées à un ensemble d'éléments dans la plage [0.1 : 0.9].

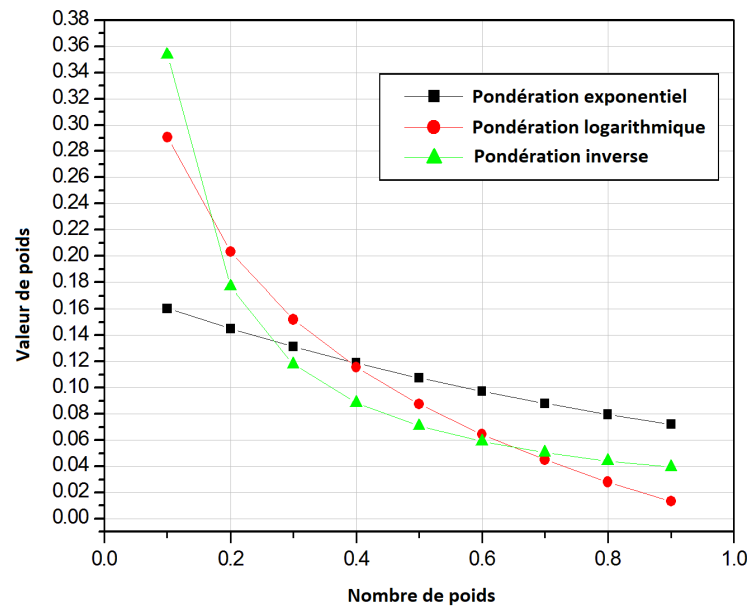


FIGURE 3.2 – Vecteurs de pondération des trois approches proposées

Les éléments du vecteur B sont classés en partant de l'élément estimé comme étant la meilleure valeur prédite avec une variance minimale jusqu'à celui considéré comme le pire avec une variance maximale. Pour cette raison, il est essentiel d'éliminer pour l'agrégation les valeurs médiocres avec des variances élevées. Plus précisément, nous devons déterminer le nombre d'éléments à agréger (taille du vecteur B). Considérons w le nombre d'éléments agrégés, où seulement le premier élément est sélectionné si $w = 1$ et tous les éléments sont utilisés pour l'agrégation lorsque $w = n$. Dans ce travail, nous sélectionnons les premiers 25%, 50% et 75% des éléments à agréger et nous choisissons la meilleure solution sur les données d'apprentissage où un seuil d'erreur quadratique moyenne (RMSE) est un paramètre défini par l'utilisateur.

L'agrégation des résultats de test estimés fournis par divers modèles GPR peut être réalisée à ce stade. C'est pourquoi trois visions de la fusion sont proposées : la fusion $IOWA^{exp}$, la fusion $IOWA^{log}$ et la fusion $IOWA^{inv}$. Une description récapitulative de ces stratégies proposées est fournie dans l'organigramme de la figure 3.3.

3.4.2.3 Procédure d'agrégation

L'idée standard de cette partie est d'effectuer la combinaison des résultats de test estimés fournis par divers modèles GPR en utilisant une moyenne simple. Néanmoins, la moyenne simple a montré certaines limites, comme souligner dans [12]. Pour effectuer une procédure d'agrégation plus élaborée, il est important d'opter pour des méthodes plus avancées telles que l'opérateur IOWA. Deux phases essentielles sont nécessaires pour sa mise en œuvre. La première étant le classement des données de test prédites ($p_{t1}, p_{t2}, \dots, p_{tn}$) sur la base des valeurs négatives de leurs variances correspondantes. La deuxième phase est le calcul de

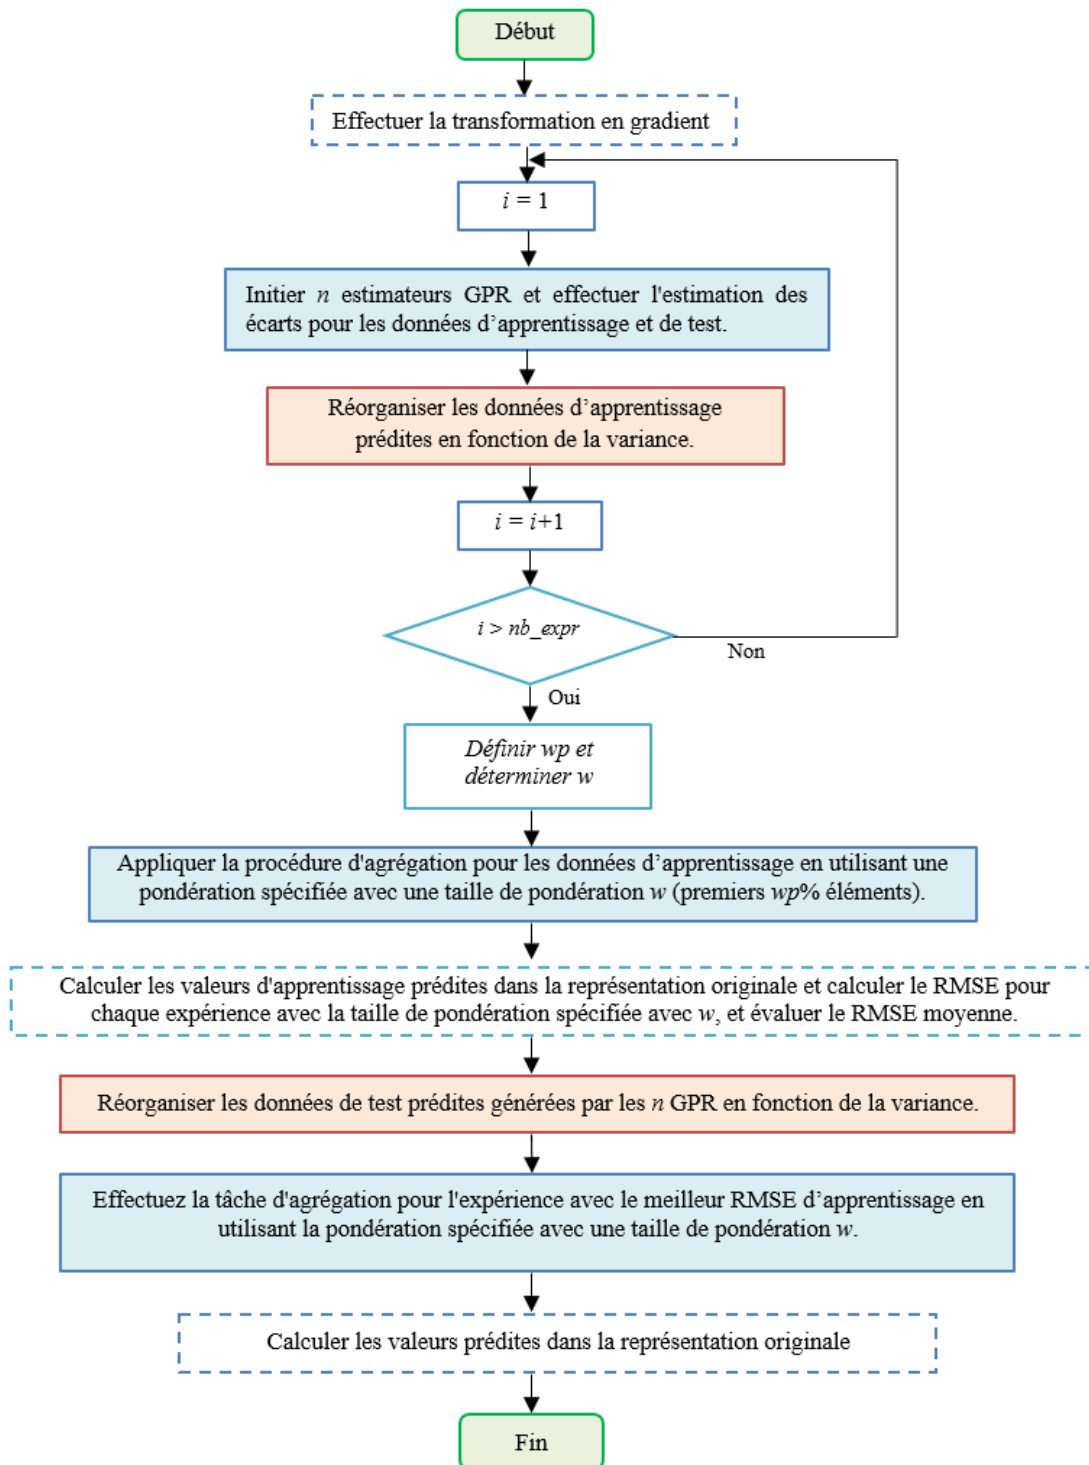


FIGURE 3.3 – Organigramme de l'approche générique proposée

la moyenne qui dépend des vecteurs de pondération proposés dans la section précédente. Par conséquent, nous obtenons trois alternatives de fusion : la fusion $IOWA^{exp}$, la fusion $IOWA^{log}$ et la fusion $IOWA^{inv}$.

3.4.3 Conversion des résultats au format primaire

A ce niveau, nous obtenons les données de prévision représentant les écarts des valeurs consécutives associées aux observations de l'ensemble de test. Pour récupérer le format original, nous prévoyons le premier élément des données de test par $\hat{y}_{n_{train}+1} = y_{n_{train}} + \hat{d}_{n_{train}}$ et estimons les éléments restants sur la base de la formule $\hat{y}_{t+1} = \hat{y}_t + \hat{d}_t$, où t varie de $n_{train} + 1$ à $n_{train} + n_{test}$.

3.5 Expériences et résultats numériques

Les batteries au lithium ont été reconnues au cours des dernières années comme un composant critique dans diverses technologies portables. Une batterie au lithium typique comprend quatre constituants élémentaires : l'anode, la cathode, le séparateur et l'électrolyte. Les ions lithium traversent l'électrolyte depuis la cathode pour atteindre l'anode pendant le processus de charge, tandis que le phénomène inverse se produit lors du processus de décharge [34]. Une vue 3D d'une batterie au lithium ainsi que son principe de fonctionnement sont décrits dans la figure 3.4.

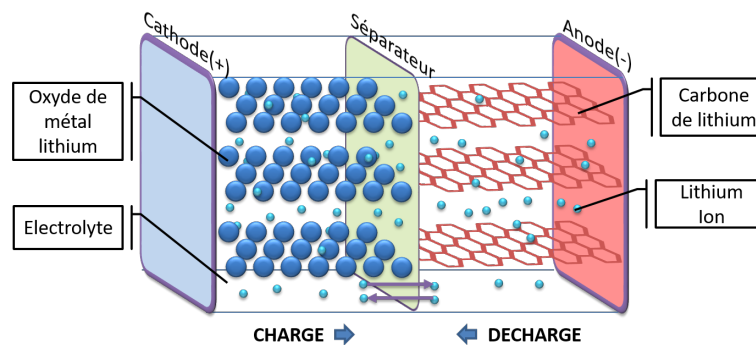


FIGURE 3.4 – Vue schématique des différents composants d'une batterie lithium-ion

L'ensemble de données des batteries disponible dans le référentiel du NASA Ames Prognostics Center of Excellence (PCoE) est adoptée pour validation dans ce travail. Par conséquent, des simulations numériques sont exécutées et évaluées sur ce jeu de données. Trois modes différents, y compris les modes de charge, de décharge et d'impédance, régissent le fonctionnement des quatre batteries lithium-ion (n° 5, 6, 7 et 18) à température ambiante. Une valeur de courant fixe (CC) de 1,5 A est utilisée pour charger les batteries jusqu'à atteindre une valeur de tension de 4,2 V. Ensuite, la tension suit une tendance constante désignée par CV jusqu'à atteindre 20 mA pour le courant de charge. Dans le second mode dit mode décharge, le courant est considéré comme constant (d'une amplitude de 2A) jusqu'à ce que les tensions des batteries étiquetées 5, 6, 7 et 18 diminuent à 2,7 V, 2,5 V, 2,2 V et 2,5 V, respectivement. Les mesures en mode impédance sont réalisées à l'aide d'une fréquence de spectroscopie d'impédance électrochimique dans la gamme [0.1 Hz : 5 kHz]. Les cycles de charge/décharge répétitifs entraînent une dégradation des performances des batteries, comme l'indiquent les mesures extraites, qui sont capables de refléter les caractéristiques d'évolution du phénomène de vieillissement. La fin de vie liée à la dégradation de chaque

batterie est définie par une réduction de 30% de la capacité nominale (c'est-à-dire une diminution de 2 Ahr à 1.4 Ahr). Dans la pratique, il est conseillé de remplacer les batteries lorsque ce seuil est atteint [35].

À base de nombreux critères d'état bien connus pour le pronostic des dispositifs à batterie, l'estimation de l'état de santé (SOH) à partir de la réduction de la capacité est adoptée dans ce travail. L'état de santé de la batterie est exprimé par :

$$SOH = \frac{C_i}{C_0} \times 100\% \quad (3.22)$$

où C_i et C_0 désignent la $i^{\text{ème}}$ capacité dégradée par rapport aux cycles et la capacité initiale, respectivement [36].

La variation du SOH en fonction des cycles des quatre batteries utilisées dans les expériences est représentée sur la figure 3.5. Il ressort clairement de cette figure que les courbes SOH des quatre batteries présentent quelques fluctuations, ce qui peut imposer des difficultés lors de la phase de prédiction. Dans le cadre de ce travail, les données de la batterie n° 5 sont sélectionnées à des fins d'apprentissage et de test.

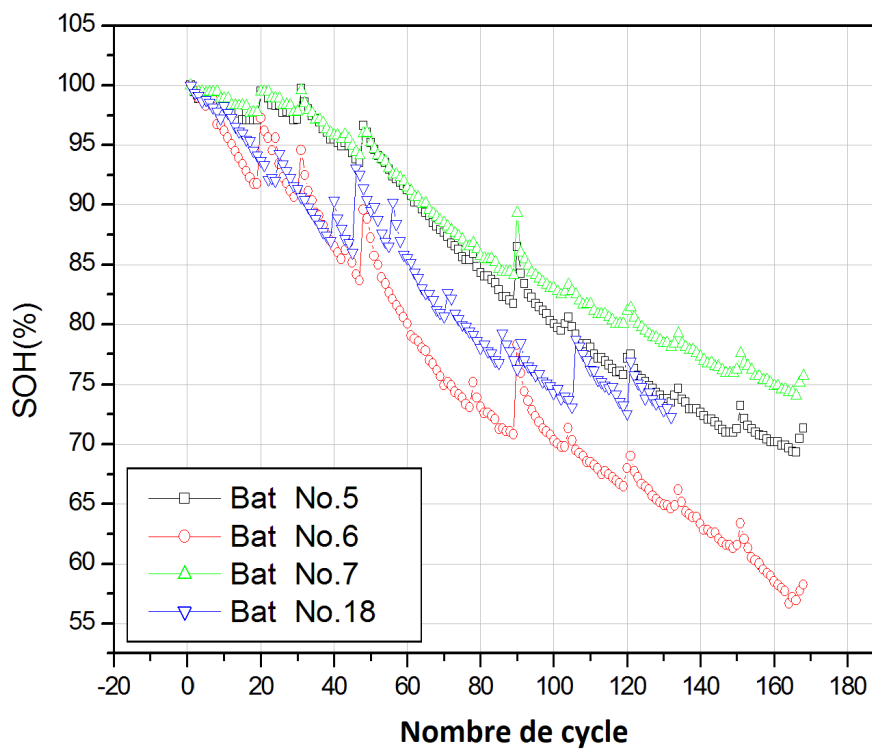


FIGURE 3.5 – Progression de la valeur SOH des batteries en fonction du nombre de cycles

Nous sélectionnons le nombre de cycles comme entrées pour les modèles GPR développés et les valeurs SOH sont considérées comme sorties. Pour la tâche d'apprentissage, les 100 premiers cycles sont définis comme entrée d'apprentissage et les cycles restants sont sélectionnés comme entrée pour la phase de test. Nous exploitons la mesure SOH pour définir les sorties d'apprentissage et de test, où les ensembles $Y_{train} = \{t, SOH(t)\}_{t=1}^{100}$ et

$Y_{test} = \{t, SOH(t)\}_{t=101}^{168}$ représentent respectivement les ensembles de données d'apprentissage et de test.

La figure 3.6 présente les valeurs de dégradation du SOH de la batterie n° 5 pour les 168 cycles comprenant les parties d'apprentissage et de test. L'approche GPR étant une méthode non paramétrique, l'entrée de test du modèle GPR comprend à la fois le nombre de cycles allant de 101 à 168 et les données d'apprentissage Y_{train} utilisant les valeurs des hyperparamètres issues de l'application d'une méthode de descente de gradient.

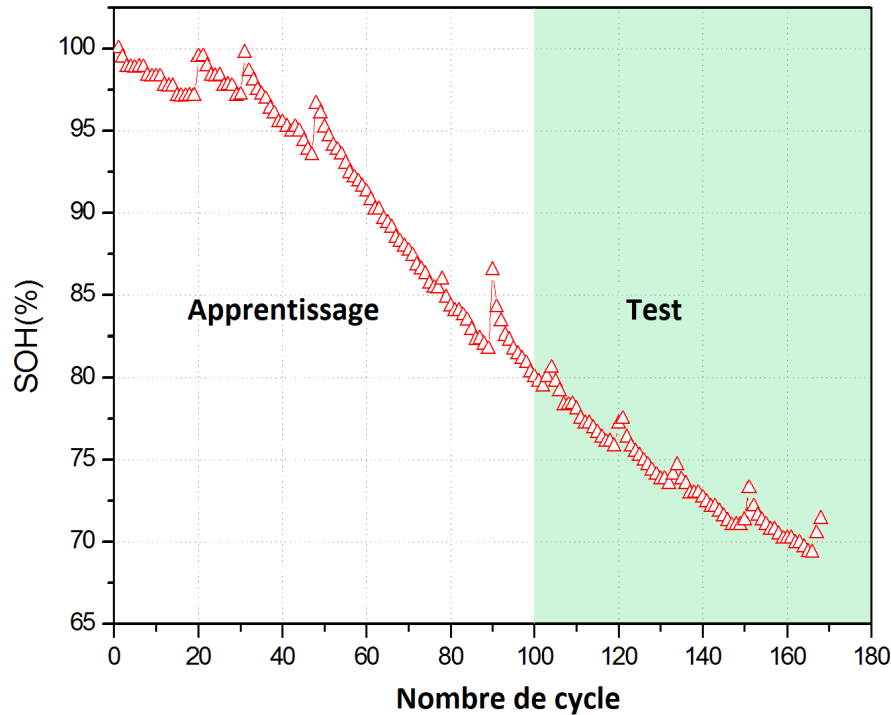


FIGURE 3.6 – Progression de la valeur SOH de la batterie n° 5 avec visualisation des zones d'apprentissage et de test

Dans certaines conditions de fonctionnement de la batterie lithium-ion, la capacité augmente pendant quelques cycles, où ces oscillations anormales sont qualifiées de phénomènes de régénération ou d'auto-recharge [37]. La prise en compte de ces phénomènes de régénération est essentielle pour des estimateurs robustes.

Dans les sous-sections suivantes, nous exposons et interprétons les résultats délivrés par l'étude des trois fonctions de pondération proposées et appliquées à l'ensemble de données sur les batteries au lithium-ion.

3.5.1 Transformation des données brutes en valeurs de gradient

La courbe de données d'apprentissage obtenue après l'application de la phase de transformation est illustrée sur la figure 3.7, où le côté droit montre les gradients générés. Les données originales sont représentées sur le côté gauche de la figure.

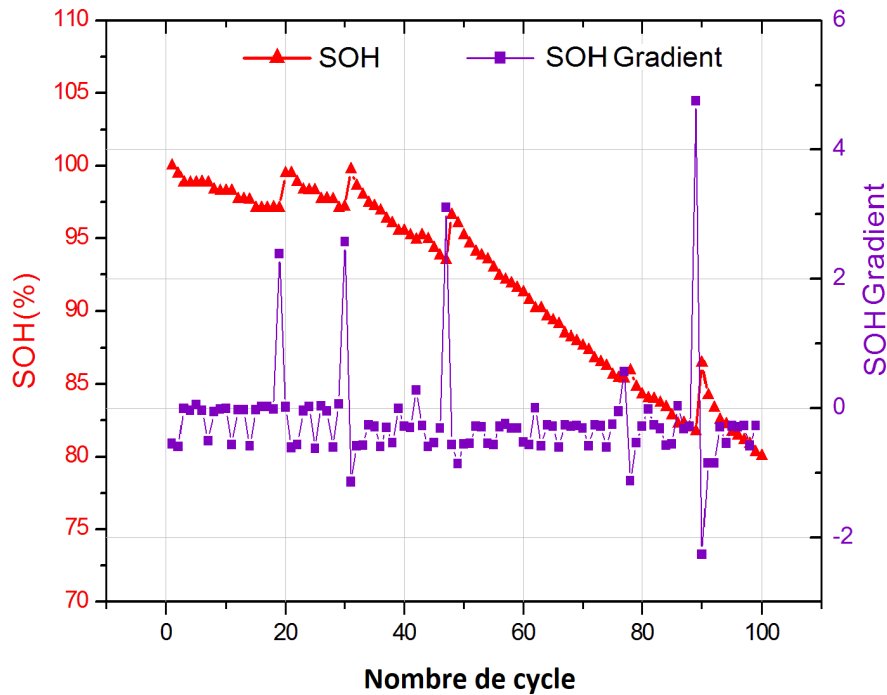


FIGURE 3.7 – Transformation des données d’apprentissage en valeurs de gradient

TABLE 3.2 – Fonctions de covariance adoptées pendant la phase de génération du GPR

Covariance	Expression
SE	$k_{SE} = \sigma^2 \exp\left(-\frac{(x_i - x_j)^2}{2l^2}\right)$
RQ	$k_{RQ} = \left(1 + \frac{(x_i - x_j)^2}{2\alpha l^2}\right)^{-\alpha}$
PER	$k_p = \sigma^2 \exp\left(-\frac{2}{l^2} \sin^2\left(\frac{w}{2\pi}(x_i - x_j)\right)\right)$
Matérn	$k_{Matern}(r) = \frac{2^{1-\nu}}{\Gamma(\nu)} \left(\frac{\sqrt{2\nu}r}{l}\right)^\nu K_\nu\left(\frac{\sqrt{2\nu}r}{l}\right)$ où Γ désigne la fonction gamma et K_ν la fonction de Bessel modifiée. Dans le domaine de l’apprentissage automatique, $\nu = 3/2$ et $\nu = 5/2$ sont souvent utilisés [21]. Dans ce travail, nous optons pour la valeur $\nu = 5/2$ avec ARD.

3.5.2 Élaboration des modèles GPR

A ce niveau, nous construisons des modèles GPR en adoptant différentes fonctions de covariance comme indiqué dans le tableau 3.2. Nous utilisons cinq instances avec différentes initialisations des hyperparamètres pour chaque modèle GPR, y compris une fonction de covariance bien définie.

Nous considérons deux configurations de fusion, où seules les fonctions SE et PER sont utilisées pour la première configuration et où toutes les fonctions de covariance répertoriées sont adoptées pour l’agrégation dans le second cas.

Avant d’accomplir la phase d’apprentissage, l’initialisation des hyperparamètres liés à un régresseur GPR spécifique est réalisée en choisissant des valeurs arbitraires dans l’intervalle $[0 : 15]$. Les valeurs optimales peuvent être obtenues sur la base de la maximisation de

la fonction de vraisemblance logarithmique [21]. Pour éviter le surajustement dans le processus de prédiction, une technique de validation croisée est exploitée. Comme la taille de nos données d'apprentissage est limitée, une politique de validation « leave one out » est choisie au lieu d'une procédure de validation croisée k-fold.

Une fois que la procédure d'apprentissage de tous les modèles GPR est terminée, les estimateurs générés sont utilisés pour prévoir les valeurs de dégradation restantes représentant les données de test. Comme résultat de la phase précédente, dix (vingt) vecteurs prédits reflétant l'estimation SOH des données de test sont obtenus pour la première (deuxième) configuration. Les vecteurs estimés sont combinés afin d'améliorer la qualité des résultats. Un ensemble de 50 essais est réalisé, où nous avons dix (vingt) estimations fournies par dix (vingt) modèles GPR agrégés dans chaque expérience. Les simulations numériques ont été effectuées sur un ordinateur portable hp avec Windows 7, Intel® Core™ i5 2430M CPU@ 2.40 GHz, 8GB de Ram, 500GB de HDD et système 64 bit.

3.5.3 Résultats des techniques d'agrégation proposées

Les trois approches proposées, à savoir la fusion $IOWA^{exp}$, la fusion $IOWA^{log}$ et la fusion $IOWA^{inv}$, sont appliquées et considérées pour comparaison. L'inconvénient de la prédiction en utilisant un simple estimateur GPR où la procédure de fusion sans introduire l'étape de transformation des gradients est révélé dans [12].

La première phase des opérateurs IOWA est l'étape de classement, où dans notre travail les sorties GPR sont classées par leurs variances. Le résultat de cette étape est un vecteur $B = [b_{t1}, b_{t2} \dots b_{tn}]$ pour chaque instant t , où l'élément b_{ti} est estimé d'être plus accepté que $b_{t(i+1)}$. Ainsi, l'agrégation peut être réalisée en utilisant les w premiers éléments au lieu d'agréger toutes les sorties délivrées. Pour cette raison, nous choisissons de combiner les premiers 25%, 50% ou 75% de l'ensemble des éléments, ce qui donne une taille w égale à 3, 5 et 8 respectivement pour la première configuration et 5, 10 et 15 pour la seconde.

La deuxième phase de la méthode IOWA est l'étape d'agrégation en utilisant la notation vectorielle :

$$F_w(p_{t1}, p_{t2}, \dots, p_{tw}) = W_w^T B_w$$

Les valeurs moyennes de tous les RMSEs d'apprentissage basés sur l'agrégation des premiers 25%, 50% et 75% des éléments en utilisant les approches proposées pour les deux configurations sont présentées dans le tableau 3.3.

Le tableau 3.3 montre clairement que la moyenne de RMSE de l'apprentissage du deuxième modèle est inférieure à celle du premier modèle, où nous n'utilisons que deux fonctions de covariance. Cela implique que l'approche de fusion utilisant quatre fonctions de covariance s'adapte aux données d'apprentissage avec plus de précision que le premier modèle n'incluant que deux fonctions de covariance. En outre, en observant les RMSEs moyennes obtenues des données d'apprentissage, nous choisissons d'utiliser les premiers 25% des éléments dans l'agrégation pour toutes les approches proposées.

TABLE 3.3 – Moyenne des RMSEs d’entraînement des premiers 25%, 50% et 75% des éléments

Configuration	Approche	25%	50%	75%
Configuration 1	$IOWA^{exp}$	0.88	1.17	1.39
	$IOWA^{log}$	0.66	0.75	0.82
	$IOWA^{inv}$	0.62	0.76	1.07
Configuration 1	$IOWA^{exp}$	0.01	0.33	0.65
	$IOWA^{log}$	0.01	0.16	0.24
	$IOWA^{inv}$	0.01	0.14	0.26

Les valeurs de prédiction basées sur les approches proposées sont présentées dans la figure 3.8, où les résultats obtenus à l’aide d’une simple technique de fusion par moyenne simple sont reportés sur le même graphique.

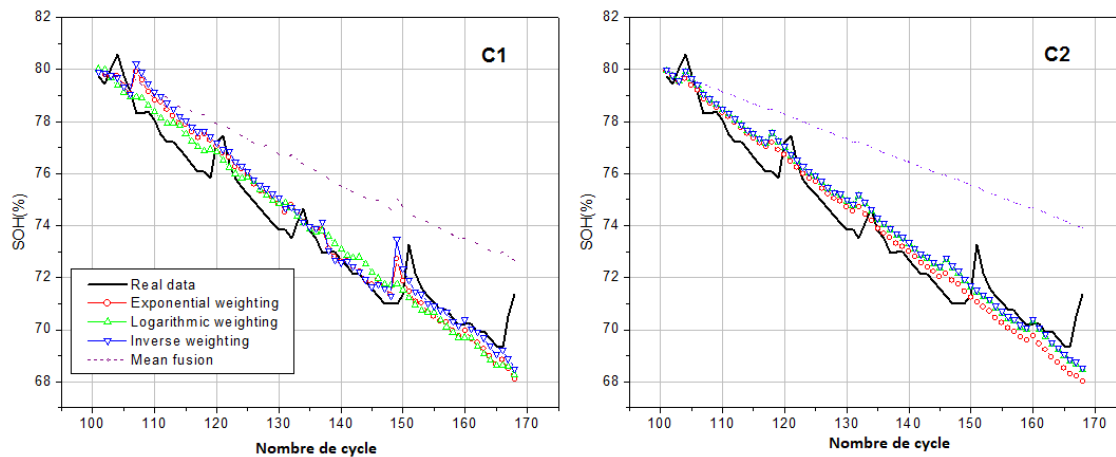


FIGURE 3.8 – Estimation de la mesure SOH basée sur des fonctions de pondération exponentielle, logarithmique et inverse en utilisant les premiers 25% des éléments (C1 : Configuration 1, C2 : Configuration 2)

Il ressort clairement de la figure 3.8 que les approches proposées fournissent de bons résultats de prédiction et expliquent avec une précision satisfaisante l’évolution de la mesure SOH. En outre, les phénomènes d’auto-régénération connus sont capturés, ce qui constitue une caractérisation pratique de la variation réelle du SOH. En outre, l’échec de la procédure standard basée sur la moyenne pour détecter l’évolution du critère SOH prouve l’utilité de l’adoption des visions de pondération proposés, comme le montre clairement la figure.

Dans la figure 3.9, nous montrons sur le même graphique les résultats fournis par les approches proposées et ceux obtenus en utilisant la méthode standard du IOWA établie à la base de la technique de descente de gradient.

Nous observons sur la figure 3.9 que toutes les prédictions donnent des résultats satisfaisants où les courbes suivent le comportement de dégradation du SOH réel, sauf pour les 30 derniers cycles, où le IOWA standard échoue en quelque sorte à suivre la progression du SOH. De plus, la méthode standard du IOWA est également capable de prendre en charge les phénomènes de régénération, ce qui est le cas des trois approches proposées.




FIGURE 3.9 – Estimation de la mesure SOH basée sur la pondération exponentielle, logarithmique et inverse en utilisant les premiers 25% des éléments en plus des résultats standards IOWA (C1 : Configuration 1, C2 : Configuration 2)

Dans ce travail, l'agrégation des meilleures valeurs en choisissant les premiers 25% des éléments classés est adoptée. Afin de montrer l'utilité d'une telle phase de sélection, nous exposons dans la figure 3.10 les résultats de prédiction basés sur l'agrégation de toutes les sorties fournies par l'ensemble des estimateurs GPR utilisant les fonctions proposées pour les deux configurations C1 et C2.

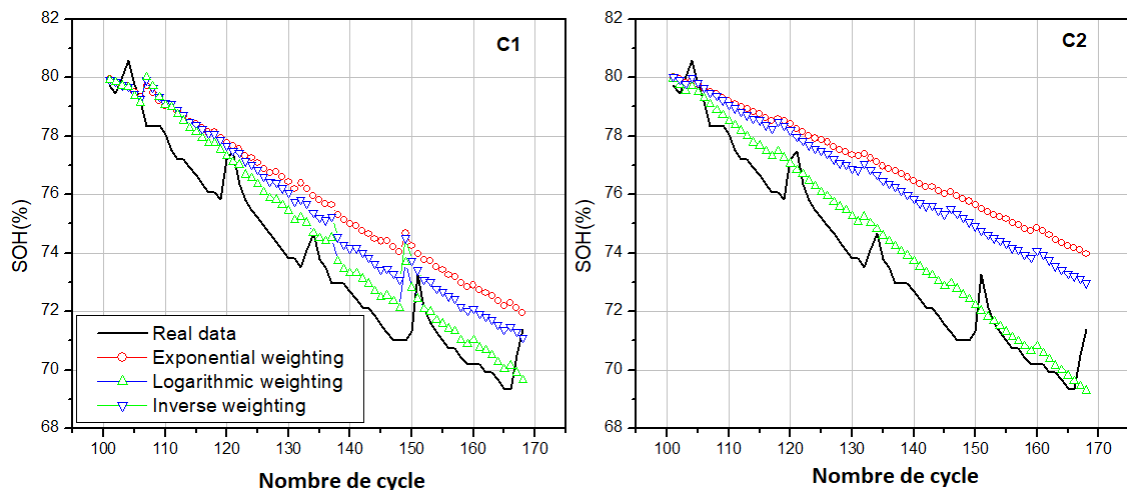


FIGURE 3.10 – Estimation de la mesure SOH basée sur la pondération exponentielle, logarithmique et inverse en utilisant tous les éléments (C1 : Configuration 1, C2 : Configuration 2)

Il ressort clairement de la figure 3.10 que l'utilisation de toutes les sorties livrées dans l'agrégation diminue la performance de l'approche proposée, ce qui constitue un argument en faveur de l'importance de l'étape de classement du IOWA et de la phase de sélection.

L'évaluation précise des approches proposées sur une base solide nécessite une validation par rapport à certains critères statistiques. Dans ce contexte, le RMSE et l'erreur absolue moyenne en pourcentage (MAPE) sont utilisées pour effectuer l'analyse comparative,

TABLE 3.4 – Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 5

Configurations	Erreurs	Approches			
		$IOWA^{exp}$	$IOWA^{log}$	$IOWA^{inv}$	IOWA standard
Configuration 1	RMSE	0.91	0.84	0.96	1.36
	MAPE(%)	0.98	0.96	0.95	1.37
Configuration 2	RMSE	0.86	0.85	0.87	1.00
	MAPE(%)	0.94	0.96	0.97	1.19

comme le souligne le tableau 3.4. Le RMSE et le MAPE sont exprimées mathématiquement par :

$$RMSE = \sqrt{\frac{\sum_{i=1}^{ntest} (y_i - \hat{y}_i)^2}{ntest}} \quad (3.23)$$

$$MAPE(\%) = \frac{100}{ntest} \sum_{i=1}^{ntest} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3.24)$$

où y_i représentent les données réelles et \hat{y}_i reflètent les valeurs prédites et $ntest$ désigne le nombre de données de test.

De tableau 3.4, on peut clairement déduire que les approches proposées donnent de bons résultats par rapport à celles fournies par la méthode standard du IOWA. En termes de RMSE, l'approche de fusion $IOWA^{log}$ fournit une erreur plus faible, suivie par la méthode de fusion $IOWA^{exp}$ et en dernière position vient la technique $IOWA^{inv}$ avec une petite différence. De même, les techniques proposées présentent de meilleures performances par rapport à la méthode conventionnelle du IOWA pour la mesure MAPE.

En ce qui concerne l'incertitude mentionnée ci-dessus, elle peut être réduite en introduisant une technique de fusion comme nous allons le décrire. En effet, nous adoptons pour la gestion de l'incertitude les mêmes fonctions analytiques proposées pour calculer la variance globale en faisant la moyenne pondérée des variances fournies par les modèles GPR autour des valeurs prédites. Dans la figure 3.11, nous élucidons les résultats obtenus en utilisant la fonction exponentielle pour la première configuration avec un niveau de confiance de 95%.

Pour valider les approches proposées, la même méthodologie est appliquée aux autres batteries (No.6, No.7 et No.18). Un résumé des résultats obtenus pour les fonctions de pondération proposés appliqués à ces batteries est fourni dans les tableaux 3.5, 3.6 et 3.7 respectivement.

D'après ces tableaux, nous constatons que les performances des trois approches proposées présentent des résultats satisfaisants en termes de valeurs RMSE et MAPE par rapport à la méthode standard du IOWA dans la majorité des cas. Comme le montre le tableau 3.7, les erreurs obtenues reflétant le SOH prédit de la batterie 18 présentent des résultats moins précis pour les deux configurations. Cette observation peut s'expliquer par le fait que certains

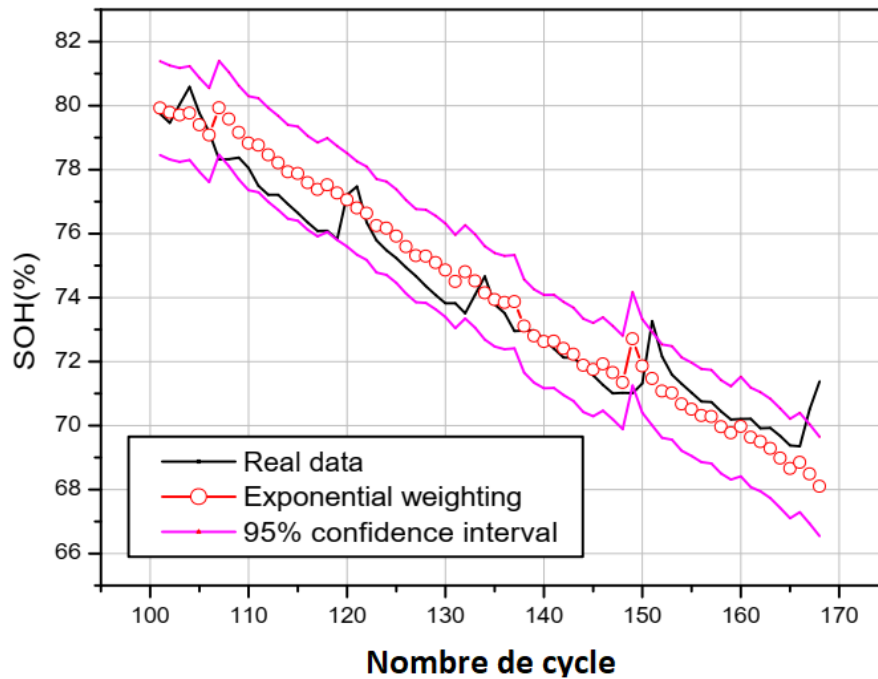


FIGURE 3.11 – Estimation de la mesure SOH basée sur la fonction de pondération exponentielle pour la première configuration avec un niveau de confiance de 95%

TABLE 3.5 – Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 6

Configurations	Erreurs	Approches			
		$IOWA^{exp}$	$IOWA^{log}$	$IOWA^{inv}$	IOWA standard
Configuration 1	RMSE	2.40	2.93	2.77	1.32
	MAPE(%)	3.43	4.29	4.00	1.72
Configuration 2	RMSE	1.67	1.89	1.98	2.74
	MAPE(%)	2.36	2.76	2.92	4.18

TABLE 3.6 – Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 7

Configurations	Erreurs	Approches			
		$IOWA^{exp}$	$IOWA^{log}$	$IOWA^{inv}$	IOWA standard
Configuration 1	RMSE	0.53	0.54	0.55	0.64
	MAPE(%)	0.51	0.52	0.53	0.67
Configuration 2	RMSE	0.84	0.93	0.91	0.54
	MAPE(%)	0.97	1.03	1.00	0.53

effets physiques sont présents et influencent le comportement du SOH, comme l'illustre la courbe associée dans la figure 3.5. En effet, le développement d'une approche efficace fournissant des résultats satisfaisants pour toutes les batteries peut être une mission lourde, en particulier lorsque des conditions réalistes sont incluses.

TABLE 3.7 – Résumé des erreurs obtenues pour les trois approches proposées, appliquées à la batterie 18

Configurations	Erreurs	Approches			
		$IOWA^{exp}$	$IOWA^{log}$	$IOWA^{inv}$	IOWA standard
Configuration 1	RMSE	4.11	4.11	4.11	4.11
	MAPE(%)	5.28	5.27	5.26	5.67
Configuration 2	RMSE	4.29	4.31	4.29	4.27
	MAPE(%)	5.52	5.54	5.50	5.50

Une autre approche alternative peut être envisagée pour la déduction des facteurs de pondération, où l'erreur d'apprentissage (RMSE) est exploitée comme une entrée pour les fonctions analytiques proposées au lieu de la variance. La principale différence dans cette vision est l'attribution du même poids à toutes les instances, alors que des poids différents sont attribués à des instances distinctes dans le cas de l'utilisation de la variance. Ainsi, quelques expériences numériques ont été réalisées afin d'évaluer cette stratégie. La figure 3.12. illustre l'évolution du critère SOH en utilisant l'approche alternative basée sur l'erreur d'apprentissage.

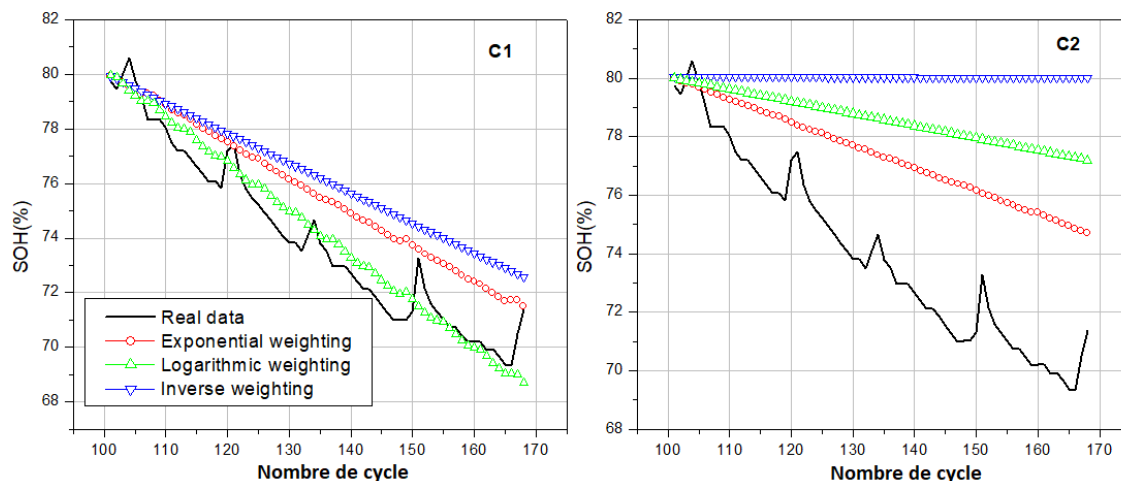


FIGURE 3.12 – Estimation de la mesure SOH basée sur des fonctions de pondération exponentielle, logarithmique et inverse en utilisant l'erreur d'apprentissage (C1 : Configuration 1, C2 : Configuration 2)

Nous fournissons un résumé des résultats obtenus pour toutes les batteries dans le tableau 3.8.

Comme nous pouvons le constater à partir de ces résultats, l'approche basée sur l'erreur d'apprentissage ne parvient pas à préserver des résultats satisfaisants pour toutes les batteries et configurations. Cela peut être interprété comme un manque de robustesse par rapport à l'approche basée sur la variance. En outre, nous remarquons que le phénomène de régénération n'est pas bien détecté, comme l'indique la figure 3.12.

En examinant les résultats obtenus, nous pouvons clairement percevoir que les approches proposées offrent des performances acceptables par rapport au modèle standard du IOWA,

TABLE 3.8 – Résumé des erreurs obtenues pour les trois approches proposées en fonction de l’erreur d’apprentissage, appliquées aux batteries 5, 6, 7 et 18

Configurations	Approche	Bat 5		Bat 6		Bat 7		Bat 18	
		RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
Configuration 1	$IOWA^{exp}$	1.85	2.31	0.85	0.98	2.37	2.72	3.08	3.62
	$IOWA^{log}$	0.82	0.93	0.90	1.04	3.16	3.62	2.47	2.76
	$IOWA^{inv}$	2.50	3.12	0.96	1.14	5.35	6.11	1.66	1.69
Configuration 1	$IOWA^{exp}$	3.72	4.63	2.63	3.45	3.15	3.62	2.38	2.62
	$IOWA^{log}$	5.13	6.35	3.68	4.94	3.16	3.62	1.92	1.91
	$IOWA^{inv}$	6.76	8.31	7.26	9.98	5.35	6.11	1.66	1.69

TABLE 3.9 – Évaluation du temps en secondes pour les deux configurations dans le cas de la batterie n° 5

Configurations	Phase	Approches			
		$IOWA^{exp}$	$IOWA^{log}$	$IOWA^{inv}$	IOWA standard
Configuration 1	Exécution des GPRs			31.52	
	Fusion	7.06×10^{-4}	7.75×10^{-4}	6.49×10^{-4}	0.54
Configuration 2	Exécution des GPRs			47.93	
	Fusion	6.98×10^{-4}	8.52×10^{-4}	6.42×10^{-4}	0.58

qui nécessite une étape d’optimisation pour apprendre les poids à partir des données observées. L’utilisation d’une technique d’optimisation pour apprendre les pondérations à partir des données d’apprentissage entraîne des charges supplémentaires en termes de temps CPU et de consommation de mémoire. Néanmoins, dans les trois méthodes de pondération proposées basées sur des fonctions analytiques explicites, on peut réduire le temps et la mémoire consommés, ce qui motive leur exploitation dans des situations de pronostic en ligne. Le tableau 3.9 confirme cette remarque en indiquant le temps CPU consommé par chaque méthode en secondes.

Il ressort clairement de ce tableau que les approches proposées prennent moins de temps que l’approche standard du IOWA. Les trois approches proposées, en plus de l’approche standard du IOWA, utilisent les mêmes résultats fournis par les modèles GPR pour réaliser l’étape de fusion. Le temps nécessaire à la génération et à l’optimisation des modèles GPR est le même pour toutes les approches, soit environ 31 secondes et 48 secondes pour la première et la deuxième configuration, respectivement. Le temps consommé lors de l’étape de fusion pour les trois approches proposées est très faible, de l’ordre de 10^{-4} secondes, comparé à celui de l’IOWA standard qui est près de 0.5 seconde. Pour cette raison, nous constatons que les trois méthodologies proposées sont très compétitives en terme de consommation de temps par rapport au IOWA standard. En fait, le temps CPU est plus significatif lorsqu’il est calculé pour les cinquante réplifications de chaque expérience, où nous avons besoin de 27 (29) secondes pour l’étape de fusion basée sur le IOWA standard dans la première configuration (deuxième configuration). Pour plus de précision, nous effectuons une analyse de sensibilité pour évaluer l’influence du nombre de GPR adoptés pour l’agrégation sur le temps d’exécution du CPU. Les figures 3.13 et 3.14 mettent en évidence le temps consommé en secondes

en fonction du nombre de GPR agrégés lors de la phase de fusion par le IOWA standard et les trois approches proposées, respectivement.




FIGURE 3.13 – Temps CPU en fonction du nombre de GPR agrégés basé sur le IOWA standard

Sur les deux figures, on peut clairement observer que l’augmentation du nombre de modèles GPR dans l’agrégation donne lieu à une tendance de quasi-monotonie en termes de temps d’exécution CPU, ce qui est plus apparent pour les trois approches proposées. De plus, nous pouvons remarquer sur la figure 3.14. que la méthode de fusion $IOWA^{inv}$ nécessite moins de temps d’exécution que les approches $IOWA^{exp}$ et $IOWA^{log}$, mais avec seulement une légère différence. Il convient de mentionner que la méthode standard du IOWA présente un temps d’exécution plus élevé en raison de sa stratégie d’optimisation basée sur la descente de gradient pour apprendre les poids à partir des données brutes.

En résumé, il est légitime d’affirmer que les trois approches proposées, $IOWA^{exp}$, $IOWA^{log}$ et $IOWA^{inv}$, fournissent non seulement de bons résultats en termes de métriques d’erreur (RMSE et MAPE) mais aussi la meilleure mesure de consommation de temps CPU par rapport à la méthode IOWA standard. Dans le tableau 3.10, nous récapitulons nos résultats obtenus par rapport à ceux fournis par des travaux similaires en termes de critères de précision et de temps d’exécution du CPU. Il est inévitable de mentionner que les simulations expérimentales dans [12] ont été réalisées en utilisant un PC avec Windows 10, AMD Ryzen 5 3400G CPU@3.70 GHz, 16 Go de RAM et un système 64 bits, offrant des performances supérieures par rapport à la spécification matérielle adoptée dans ce travail.




FIGURE 3.14 – Temps CPU en fonction du nombre de GPR agrégés selon les trois approches proposées

3.5.4 Discussion

Discussion En arrivant à ce stade, l'analyse vigilante des nombreuses simulations réalisées nous permet de discerner les principaux avantages et limites de l'approche de fusion proposée. Tout d'abord, les avantages se concentrent essentiellement sur les points suivants :

- Réduction du temps et de la mémoire nécessaire à la réalisation des simulations numériques ;
- Flexibilité et facilité d'utilisation sans besoin d'une connaissance approfondie du sujet étudié ;
- Gain d'une plus grande précision grâce à la robustesse de la structure pondérée des modèles GPR ;
- Gestion fiable de l'incertitude en fournissant des bornes de confiance avec les résultats prédits ;
- Prise en charge de petits échantillons de données numérique.

Néanmoins, l'approche proposée souffre de quelques déficiences, notamment :

- L'absence de méthodes dédiées pour ajuster certains paramètres importants tels que la portion des sorties des GPR à fusionnés dans les méthodes proposées ;
- Aucune garantie d'optimalité des pondérations fournies par les fonctions analytiques explicites ;

TABLE 3.10 – Résumé des erreurs obtenues pour les trois approches proposées en fonction de l’erreur d’apprentissage, appliquées aux batteries 5, 6, 7 et 18

Réf	Approche	Temps CPU en seconds		Bat 5		Bat 6		Bat 7		Bat 18	
		Modèles	Fusion	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
He et al. [38]	SMK-GPR	N/A	N/A	1.38	1.65	7.08	10.60	1.88	1.91	N/A	N/A
	P-MGPR	N/A	N/A	1.36	1.55	2.12	2.96	1.14	1.09	N/A	N/A
	SE-MGPR	N/A	N/A	1.20	1.38	2.11	2.93	1.07	1.02	N/A	N/A
Zhou et al. [39]	Model 3	N/A	N/A	0.83	0.91	1.71	2.18	1.71	1.12	N/A	N/A
	Model 2	N/A	N/A	0.83	0.94	0.81	0.99	0.81	0.73	N/A	N/A
	Model 1	N/A	N/A	0.74	0.80	0.82	1.00	0.82	0.74	N/A	N/A
Bouzenita et al. [12]	IOWA-(PER, ULL)	83.12	4.00	1.08	N/A	1.30	N/A	0.50	N/A	4.11	N/A
	IOWA-(PER, Matern)	74.97	4.10	0.80	N/A	1.30	N/A	0.81	N/A	3.96	N/A
	MinVar-(PER, EYE)	66.93	0.01	1.37	N/A	5.68	N/A	1.00	N/A	1.73	N/A
Approches proposées (Config. 1)	$IOWA^{exp}$	31.52	7.06×10^{-4}	0.91	0.98	2.40	3.43	0.53	0.51	4.11	5.28
	$IOWA^{log}$	31.52	7.75×10^{-4}	0.84	0.96	2.93	4.29	0.54	0.52	4.11	5.27
	$IOWA^{inv}$	31.52	6.49×10^{-4}	0.96	0.95	2.77	4.00	0.55	0.53	4.11	5.26
	IOWAstandard	31.52	0.54	1.36	1.37	1.32	1.72	0.64	0.67	4.39	5.67
Approches proposées (Config. 2)	$IOWA^{exp}$	47.93	6.98×10^{-4}	0.86	0.94	1.67	2.36	0.84	0.97	4.29	5.52
	$IOWA^{log}$	47.93	8.52×10^{-4}	0.85	0.96	1.89	2.76	0.93	1.03	4.31	5.54
	$IOWA^{inv}$	47.93	6.42×10^{-4}	0.87	0.97	1.98	2.92	0.91	1.00	4.29	5.50
	IOWAstandard	47.93	0.58	1.00	1.19	2.74	4.18	0.54	0.53	4.27	5.50

- L’application d’une seule fonction explicite à l’ensemble de l’historique des données peut ne pas être, dans certains cas, le meilleur choix car la sélection de la fonction peut dépendre de l’instance.

3.6 Conclusion

Dans ce chapitre, nous avons étudié les performances de nouveaux cadres de fusion élaborés par l’utilisation conjointe de la méthode de régression par processus gaussien et d’opérateurs de moyenne pondérée ordonnée induite IOWA incluant des fonctions de pondération explicites. Le schéma de fusion a été construit à la base de plusieurs estimateurs GPR, chacun défini par sa propre fonction de covariance et ses hyperparamètres initiaux. La méthode du calcul de la moyenne pondérée ordonnée induite a été adoptée pour combiner les résultats fournis par les modèles GPR. Au lieu d’estimer les poids à partir des données observées, trois fonctions de pondération analytiques ont été proposées et adoptées dans ce travail : la pondération exponentielle, la pondération logarithmique et la fonction de pondération inverse. Les valeurs de gradient des données brutes ont été utilisées comme nouvelles données d’apprentissage au lieu de l’observation originale, ce qui a permis de gagner plus d’efficacité, comme nous l’avons prouvé dans le chapitre précédent. En outre, les fonctions proposées se sont avérées efficaces pour gérer l’incertitude en estimant les intervalles de confiance. Différentes configurations ont été considérées afin de valider les approches de fusion proposées. Les trois fonctions de pondération proposées ont prouvé leur capacité à prédire la durée de vie utile restante de quatre batteries lithium-ion. Il convient de mentionner que les résultats obtenus sont très encourageants par rapport à la méthode conventionnelle du IOWA, principalement en termes de réduction du temps de calcul.

Dans le chapitre suivant, nous étudions les capacités des métaheuristiques pour l’ajustement des poids et des hyper-paramètres dans le contexte des approches hybrides. Pour atteindre cet objectif, nous adoptons les algorithmes génétiques comme outil de fusion dans

lequel un ensemble de différents régresseurs comprenant des modèles GPR et des estimateurs ANFIS est construit.

Références

1. BAUR, M., ALBERTELLI, P. & MONNO, M. A review of prognostics and health management of machine tools. *The International Journal of Advanced Manufacturing Technology* **107**. Number : 5, 2843-2863. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-020-05202-3> (1^{er} mars 2020).
2. MOTAHARI-NEZHAD, M. & JAFARI, S. M. Bearing remaining useful life prediction under starved lubricating condition using time domain acoustic emission signal processing. *Expert Systems with Applications* **168**, 114391. ISSN : 0957-4174. <http://www.sciencedirect.com/science/article/pii/S0957417420310630> (15 avr. 2021).
3. ZHANG, S.-J., KANG, R. & LIN, Y.-H. Remaining useful life prediction for degradation with recovery phenomenon based on uncertain process. *Reliability Engineering & System Safety* **208**, 107440. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S0951832021000119> (1^{er} avr. 2021).
4. MONTERO-JIMENEZ, J. J., SCHWARTZ, S., VINGERHOEDS, R., GRABOT, B. & SALAÜN, M. Towards multi-model approaches to predictive maintenance : A systematic literature survey on diagnostics and prognostics. *Journal of Manufacturing Systems* **56**, 539-557. ISSN : 0278-6125. <http://www.sciencedirect.com/science/article/pii/S0278612520301187> (1^{er} juill. 2020).
5. PENG, Y., DONG, M. & ZUO, M. J. Current status of machine prognostics in condition-based maintenance : a review. *The International Journal of Advanced Manufacturing Technology* **50**, 297-313. ISSN : 0268-3768, 1433-3015. <https://link.springer.com/article/10.1007/s00170-009-2482-0> (1^{er} sept. 2010).
6. WANG, Y., ZHAO, Y. & ADDEPALLI, S. Remaining Useful Life Prediction using Deep Learning Approaches : A Review. *Procedia Manufacturing. Proceedings of the 8th International Conference on Through-Life Engineering Services – TESConf 2019* **49**, 81-88. ISSN : 2351-9789. <http://www.sciencedirect.com/science/article/pii/S2351978920316528> (1^{er} jan. 2020).
7. GUO, J., LI, Z. & LI, M. A Review on Prognostics Methods for Engineering Systems. *IEEE Transactions on Reliability* **69**. Number : 3 Conference Name : IEEE Transactions on Reliability, 1110-1129. ISSN : 1558-1721 (sept. 2020).
8. XIA, T. *et al.* Recent advances in prognostics and health management for advanced manufacturing paradigms. *Reliability Engineering & System Safety* **178**, 255-268. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S095183201731459X> (1^{er} oct. 2018).
9. NIU, G. & YANG, B.-S. Intelligent condition monitoring and prognostics system based on data-fusion strategy. *Expert Systems with Applications* **37**, 8831-8840. ISSN : 0957-4174. <http://www.sciencedirect.com/science/article/pii/S095741741000518X> (1^{er} déc. 2010).
10. ELATTAR, H. M., ELMINIR, H. K. & RIAD, A. M. Prognostics : a literature review. *Complex & Intelligent Systems* **2**, 125-154. ISSN : 2199-4536, 2198-6053. <https://link.springer.com/article/10.1007/s40747-016-0019-3> (1^{er} juin 2016).

11. LEI, Y. *et al.* Machinery health prognostics : A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing* **104**, 799-834. ISSN : 0888-3270. <http://www.sciencedirect.com/science/article/pii/S0888327017305988> (1^{er} mai 2018).
12. BOUZENITA, M., MOUSS, L.-H., MELGANI, F. & BENTRCIA, T. New fusion and selection approaches for estimating the remaining useful life using Gaussian process regression and induced ordered weighted averaging operators. *Quality and Reliability Engineering International* **36**, 2146-2169. ISSN : 1099-1638. <https://onlinelibrary.wiley.com/doi/abs/10.1002/qre.2688> (2020).
13. GEBRAEEL, N., LAWLEY, M., LIU, R. & PARMESHWARAN, V. Residual life predictions from vibration-based degradation signals : a neural network approach. *IEEE Transactions on Industrial Electronics* **51**. Conference Name : IEEE Transactions on Industrial Electronics, 694-700. ISSN : 1557-9948 (juin 2004).
14. GOEBEL, K., EKLUND, N. & BONANNI, P. *Fusing competing prediction algorithms for prognostics in 2006 IEEE Aerospace Conference 2006* IEEE Aerospace Conference. ISSN : 1095-323X (mars 2006), 10 pp.-.
15. XU, J. & XU, L. Health management based on fusion prognostics for avionics systems. *Journal of Systems Engineering and Electronics* **22**, 428-436 (juin 2011).
16. LIU, J., VITELLI, V., ZIO, E. & SERAOU, R. A Novel Dynamic-Weighted Probabilistic Support Vector Regression-Based Ensemble for Prognostics of Time Series Data. *IEEE Transactions on Reliability* **64**. Conference Name : IEEE Transactions on Reliability, 1203-1213. ISSN : 1558-1721 (déc. 2015).
17. LI, Z., GOEBEL, K. & WU, D. Degradation Modeling and Remaining Useful Life Prediction of Aircraft Engines Using Ensemble Learning. *Journal of Engineering for Gas Turbines and Power* **141**, 041008–041008-10. ISSN : 0742-4795. <http://dx.doi.org/10.1115/1.4041674> (16 nov. 2018).
18. LI, Z., WU, D., HU, C. & TERPENNY, J. An ensemble learning-based prognostic approach with degradation-dependent weights for remaining useful life prediction. *Reliability Engineering & System Safety. Impact of Prognostics and Health Management in Systems Reliability and Maintenance Planning* **184**, 110-122. ISSN : 0951-8320. <http://www.sciencedirect.com/science/article/pii/S0951832017308104> (1^{er} avr. 2019).
19. XIA, T., SONG, Y., ZHENG, Y., PAN, E. & XI, L. An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation. *Computers in Industry* **115**, 103182. ISSN : 0166-3615. <http://www.sciencedirect.com/science/article/pii/S0166361519303987> (1^{er} fév. 2020).
20. CHENG, Y., SONG, D., WANG, Z., LU, C. & ZERHOUNI, N. An ensemble prognostic method for lithium-ion battery capacity estimation based on time-varying weight allocation. *Applied Energy* **266**, 114817. ISSN : 0306-2619. <http://www.sciencedirect.com/science/article/pii/S0306261920303299> (15 mai 2020).
21. RASMUSSEN, C. E. & WILLIAMS, C. K. I. *Gaussian Processes for Machine Learning* <http://www.gaussianprocess.org/gpml/chapters/RW.pdf> (The MIT Press Cambridge MA, 2006).
22. KOCIJAN, J. & TANKO, V. *Prognosis of gear health using Gaussian process model in 2011 IEEE EUROCON - International Conference on Computer as a Tool 2011* IEEE EUROCON - International Conference on Computer as a Tool (avr. 2011), 1-4.
23. CHEN, Z. & WANG, B. How priors of initial hyperparameters affect Gaussian process regression models. *Neurocomputing* **275**, 1702-1710. ISSN : 09252312. <https://linkinghub.elsevier.com/retrieve/pii/S092523121731679X> (jan. 2018).

24. YAGER, R. On ordered weighted averaging aggregation operators in multicriteria decision making. *IEEE Trans. Syst., Man, Cybern* **18**, 183-190. ISSN : 0018-9472 (jan. 1988).
25. YAGER, R. & FILEV, D. P. Induced ordered weighted averaging operators. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)* **29**, 141-150. ISSN : 1083-4419 (avr. 1999).
26. YAGER, R. Generalized OWA Aggregation Operators. *Fuzzy Optimization and Decision Making* **3**, 93-107. ISSN : 1568-4539, 1573-2908. <https://link.springer.com/article/10.1023/B:FODM.0000013074.68765.97> (1^{er} mars 2004).
27. CHICLANA, F., HERRERA-VIEDMA, E., HERRERA, F. & ALONSO, S. Some induced ordered weighted averaging operators and their use for solving group decision-making problems based on fuzzy preference relations. *European Journal of Operational Research* **182**, 383-399. ISSN : 0377-2217. <http://www.sciencedirect.com/science/article/pii/S0377221706008095> (1^{er} oct. 2007).
28. ZHOU, S. M., CHICLANA, F., JOHN, R. I. & GARIBALDI, J. M. Alpha-Level Aggregation : A Practical Approach to Type-1 OWA Operation for Aggregating Uncertain Information with Applications to Breast Cancer Treatments. *IEEE Transactions on Knowledge and Data Engineering* **23**, 1455-1468. ISSN : 1041-4347 (oct. 2011).
29. ZENG, S., LI, W. & MERIGÓ, J. M. Extended induced ordered weighted averaging distance operators and their application to group decision-making. *International Journal of Information Technology & Decision Making* **12**, 789-811. ISSN : 0219-6220. <http://www.worldscientific.com/doi/abs/10.1142/S0219622013500296> (1^{er} juill. 2013).
30. YAGER, R. R. Induced aggregation operators. *Fuzzy Sets and Systems. Preference Modeling and Applications* **137**, 59-69. ISSN : 0165-0114. <http://www.sciencedirect.com/science/article/pii/S0165011402004323> (1^{er} juill. 2003).
31. YAGER, R., KACPRZYK, J. & BELIAKOV, G. *Recent Developments in the Ordered Weighted Averaging Operators : Theory and Practice* éd. par KACPRZYK, J. ISBN : 978-3-642-17909-9 978-3-642-17910-5. <http://link.springer.com/10.1007/978-3-642-17910-5> (Springer Berlin Heidelberg, Berlin, Heidelberg, 2011).
32. VLUYMANS, S., MAC PARTHALÁIN, N., CORNELIS, C. & SAEYS, Y. Weight selection strategies for ordered weighted average based fuzzy rough sets. *Information Sciences* **501**, 155-171. ISSN : 0020-0255. <http://www.sciencedirect.com/science/article/pii/S0020025519305122> (1^{er} oct. 2019).
33. FILEV, D. & YAGER, R. *Learning OWA operator weights from data* in *Proceedings of 1994 IEEE 3rd International Fuzzy Systems Conference* Proceedings of 1994 IEEE 3rd International Fuzzy Systems Conference (juin 1994), 468-473 vol.1.
34. ZUBI, G., DUFO-LÓPEZ, R., CARVALHO, M. & PASAOGLU, G. The lithium-ion battery : State of the art and future perspectives. *Renewable and Sustainable Energy Reviews* **89**, 292-308. ISSN : 1364-0321. <http://www.sciencedirect.com/science/article/pii/S1364032118300728> (1^{er} juin 2018).
35. SAHA, B. & GOEBEL, K. *Battery data set, NASA ames prognostics data repository*. NASA Ames 2007. <http://ti.arc.nasa.gov/project/%20prognostic-data-repository>.
36. MONTOYA-BEDOYA, S., SABOGAL-MONCADA, L. A., GARCIA-TAMAYO, E. & MARTÍNEZ-TEJADA, H. V. A Circular Economy of Electrochemical Energy Storage Systems : Critical Review of SOH/RUL Estimation Methods for Second-Life Batteries. *Green Energy and Environment*. Publisher : IntechOpen. <https://www.intechopen.com/books/green-energy-and-environment/a-circular-economy-of-electrochemical-energy-storage-systems-critical-review-of-soh-rul-estimation-m> (23 mars 2020).

37. LIU, D., PANG, J., ZHOU, J., PENG, Y. & PECHT, M. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression. *Microelectronics Reliability* **53**, 832-839. ISSN : 0026-2714. <http://www.sciencedirect.com/science/article/pii/S0026271413000747> (1^{er} juin 2013).
38. HE, Y.-J., SHEN, J.-N., SHEN, J.-F. & MA, Z.-F. State of health estimation of lithium-ion batteries : A multiscale Gaussian process regression modeling approach. *American Institute of Chemical Engineers Journal* **61**, 1589-1600. ISSN : 1547-5905. <http://onlinelibrary.wiley.com/doi/10.1002/aic.14760/abstract> (1^{er} mai 2015).
39. ZHOU, D. *et al.* Prognostics for State of Health of Lithium-Ion Batteries Based on Gaussian Process Regression. *Mathematical Problems in Engineering* **2018**. Publisher : Hindawi Volume : 2018, e8358025. ISSN : 1024-123X. <https://www.hindawi.com/journals/mpe/2018/8358025/> (1^{er} avr. 2018).

Chapitre 4

Développement d'un algorithme génétique hybride pour le pronostic industriel

Résumé : Une nouvelle approche hybride de pronostic à base des algorithmes génétiques est proposée et met en œuvre dans ce chapitre. L'algorithme génétique développé est consacré à l'attribution des poids à un ensemble d'estimateurs (ANFIS et GPR) construit pour la prédiction de la durée de vie de bon fonctionnement restante. Dans cette approche, le processus de pronostic est effectué en trois phases principales. La première est l'initialisation des paramètres de modèle et la préparation des données d'apprentissage pour les prédicteurs concurrents. Pour la deuxième phase, une procédure d'optimisation est effectuée afin de trouver une meilleure solution développée sous forme d'un chromosome comportant un ensemble de prédicteurs avec les meilleurs poids associés. La dernière phase est l'étape de prédiction, où à base de la meilleure solution trouvée, une tâche d'agrégation des prédicteurs obtenus est effectuée en utilisant les poids retournés par l'AG développé. Pour montrer l'efficacité de l'approche proposée, une évaluation à l'aide de données des batteries de type lithium-ion est conduite, où les résultats obtenus confirment l'utilité de l'AG hybride développé. Ce travail peut fournir des orientations dans le but de développer des stratégies hybrides robustes pour les tâches de pronostic.

4.1 Introduction

La façon de maintenir les équipements constitue une fonction critique dans tout système de production. Cette fonction a évolué au cours des années d'une stratégie simple à une stratégie complexe. À l'origine, l'intervention de maintenance était exécutée en fonction de l'occurrence des défaillances, puis une nouvelle stratégie a été introduite, connue sous le nom de maintenance préventive. Dans ce contexte, l'intervention est effectuée à des intervalles de temps programmés et déterminés sur la base de certains paramètres statistiques de fiabilité. Ensuite, l'intervention est réalisée suite au déclenchement d'une alarme lorsqu'un indicateur de surveillance est dépassé. Cette stratégie est appelée maintenance conditionnelle (CBM), qui est la stratégie de maintenance la plus populaire ces dernières années. De ce fait, un nouveau concept appelé Pronostic et gestion de l'état (en anglais : Prognostics and Health Management (PHM)) est introduit et largement utilisé par les chercheurs et les industriels afin de surveiller et contrôler les systèmes complexes [1]. La figure 4.1 illustre l'évolution de la stratégie de maintenance au fil des années, de la maintenance non programmée aux stratégies prédictives et proactives [2].

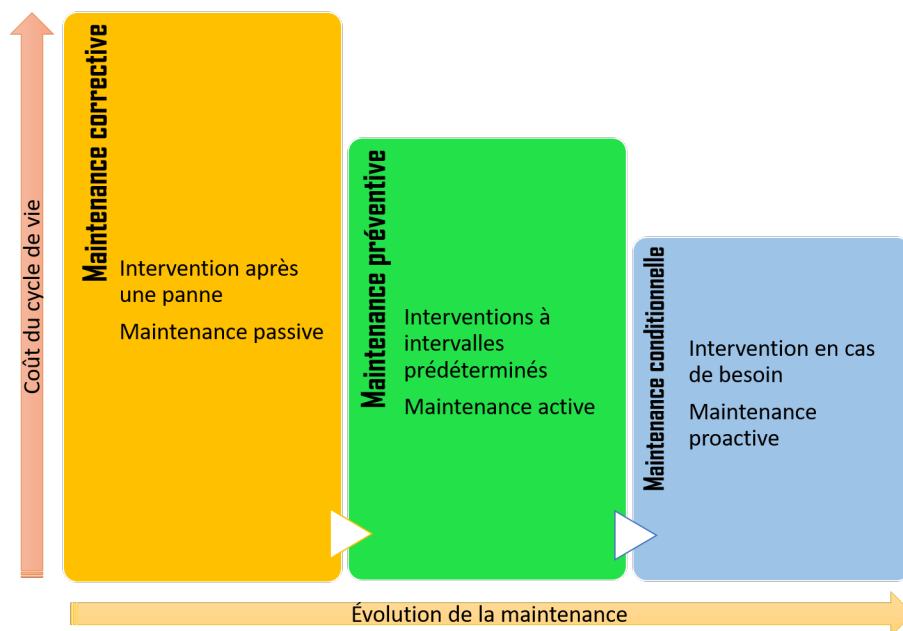


FIGURE 4.1 – Illustration de différents concepts de pronostic

Le concept PHM a émergé dans la fabrication intelligente avec l'arrivée de l'industrie 4.0 dans le but de fournir un fonctionnement sûr et un plan de maintenance optimisé [3]. Le modèle PHM décrit la capacité du système de surveillance à prévoir le comportement futur du système et à prédire la durée de vie utile restante (RUL). Une telle estimation est basée sur l'état actuel dans lequel le défi est de savoir quand et comment appliquer la stratégie PHM [4].

Depuis l'introduction de ce concept, plusieurs approches de pronostic ont été proposées, notamment des modèles basés sur la physique, sur les données, sur l'expérience et des modèles hybrides. La combinaison peut être construite sur trois architectures principales à

savoir la combinaison en série, la combinaison en parallèle et la combinaison intégrée ayant plus de capacités. Dans la combinaison parallèle, deux ou plusieurs méthodes de pronostic partagent les mêmes sorties ou des sorties connexes et fournissent des résultats compétitifs, qui sont fusionnés pour fournir des résultats avec une plus grande précision [5]. La fusion des résultats fournis est réalisée à l'aide d'un outil d'agrégation vigilant, où davantage de performance est gagnée par rapport à un modèle élémentaire [6]. La moyenne simple, la moyenne pondérée et les techniques d'intelligence artificielle sont des méthodes d'agrégation largement adoptées dans le domaine du pronostic. Parmi les techniques d'intelligence artificielle, nous pouvons distinguer les algorithmes génétiques (AG) utilisés pour agréger les résultats fournis par les modèles sélectionnés pour la fusion. Ce type d'algorithme peut être exploité pour estimer le vecteur de pondération optimal à mettre en œuvre dans l'agrégation [7].

Dans le présent chapitre, nous proposons un nouvel algorithme génétique hybride traitant de l'estimation de la durée de vie utile restante. Dans ce contexte, l'AG est introduit pour allouer un poids optimal à chaque régresseur utilisé lors de l'agrégation. Nous avons choisi d'utiliser un ensemble de régresseurs différents, chacun caractérisé par ses propres méthodes, fonctions et paramètres. Tout d'abord, nous préparons nos données sous une forme appropriée à nos régresseurs sélectionnés et nous initialisons tous les paramètres initiaux définis, y compris les prédicteurs et les paramètres génétiques. Un codage du chromosome est ensuite proposé pour modéliser les solutions possibles d'une population et la meilleure solution est fournie après un nombre fixe d'itérations. Les opérateurs connus de l'AG, à savoir la sélection, le croisement et la mutation, sont exploités pour générer des nouvelles solutions lors du déroulement de la procédure d'optimisation. Enfin, la meilleure solution obtenue est utilisée pour entamer la phase de prédiction et estimer la durée de vie restante finale. Dans la meilleure solution générée, un ensemble de prédicteurs est sélectionné pour la procédure d'agrégation en utilisant le vecteur de pondération obtenu.

La section 4.2 de ce chapitre est consacrée à la présentation de quelques travaux connexes dans la littérature. La section 4.3 expose les principaux concepts des techniques adoptées : les techniques AG, GPR et ANFIS. Dans la section 4.4, nous élucidons sous une forme concise les principaux composants de l'approche hybride de pronostic proposée. Des simulations expérimentales sont révélées dans la section 4.5, où une comparaison en termes de certains critères de performance est effectuée par rapport à des études similaires. Nous terminons ce chapitre par quelques remarques et conclusions.

4.2 Etat de l'art

Récemment, les modèles hybrides de pronostic ont attiré l'attention des ingénieurs dans l'industrie et des chercheurs en raison de leur précision et de leurs performances accrues par rapport à un modèle unique [7]. Zhang et al. ont proposé un modèle de pronostic hybride pour estimer la durée de vie restante des batteries en combinant la colonie d'abeilles artificielle (ABC), les forêts aléatoires (RF) et le réseau neuronal de régression générale (GRNN). Les RF ont été choisies pour classer les caractéristiques sélectionnées et la méthode ABC a

été utilisée pour optimiser les paramètres du modèle. Le modèle GRNN a été réservé pour réaliser la tâche de prédiction [8]. Une approche combinée utilisant une méthode à base de modèle et une technique basée sur les données a été proposée pour prédire la durée de vie des batteries dans [9]. Les auteurs ont choisi d'utiliser un modèle empirique avec une régression par vecteur de support pour réaliser le modèle hybride proposé. Les paramètres du modèle empirique ont été mis à jour à l'aide d'un filtre à particules et un algorithme de colonies d'abeilles artificielles a été utilisé pour optimiser les performances du modèle de régression à vecteur de support. En utilisant neuf turbomoteurs fournis par le jeu de données de la NASA, les auteurs dans [10] ont proposé un modèle de pronostic hybride pour estimer la durée de vie utile restante. Le schéma de fusion est réalisé en agrégeant un modèle basé sur la physique et des algorithmes d'apprentissage profond. Les paramètres du modèle sont estimés par la calibration du modèle du système en utilisant la lecture des capteurs et la dynamique du système. Zang et al. proposent une fusion de la méthode du filtre à particules basée sur la loi de Paris avec un réseau neuronal à anticipation (FNN) pour estimer la durée de vie utile restante des câbles D des équipements de transmission ferroviaire. En raison du manque de capteurs dans tels systèmes et de l'absence de modèle physique de l'équipement, les auteurs ont choisi d'analyser les modes de défaillance, les mécanismes, les causes et les effets du système et ont obtenu trois groupes d'ensembles de données sur le cycle de vie en utilisant les tests de vie accélérés d'Ansys [11]. Pour prédire avec précision la durée de vie utile restante d'une batterie lithium-ion, un modèle hybride basé sur les machines à vecteurs de support des moindres carrés (LSSVM) et la méthode "Unscented Particle Filter" (UPF) a été proposé par Li et al. [12]. L'état de dégradation de la capacité de la batterie est mis à jour en utilisant deux filtres d'algorithme de fusion et la méthode LSSVM a été adoptée comme équation de mesure dans le modèle UPF. La fonction de densité de probabilité (PDF) a été réalisée pour traiter l'incertitude du pronostic. Une stratégie de combinaison basée sur un réseau neuronal, un réseau de mémoire à long terme (LSTM) et un AG a été proposée dans [13] pour prédire la charge des supercondensateurs en régime permanent et la durée de vie utile restante. La capacité de recherche globale de l'AG utilisé est améliorée en utilisant la méthode quadratique séquentielle comme recherche locale. Les auteurs ont validé leur travail en utilisant des données historiques en ligne et hors ligne. Han et al. ont proposé un travail de pronostic par fusion traitant de l'estimation de la durée de vie utile restante des batteries. Un modèle semi-empirique amélioré de dégradation de la capacité a été introduit en tenant compte de la résistance interne et de l'effet de la température [14]. Un modèle de pronostic hybride basé sur la méthode "Adaptive Unscented Kalman Filter" (AUKF) avec une régression de vecteur de support optimisée par algorithme génétique (GA-SVR) a été proposé par Xue et al [15]. La méthode AUKF a été sélectionnée pour les mises à jour de la covariance du bruit de processus et de la covariance du bruit d'observation. Les paramètres SVR sont mis à jour à l'aide d'un AG dans lequel une prédiction à plusieurs étapes est effectuée. Dans cette étude, l'ensemble de données de la NASA sur les batteries lithium-ion est utilisé comme référence pour valider le travail proposé.

Notre exploitation des AGs comme outil d'agrégation et de spécification de vecteur de pondération est motivée par leurs succès non seulement dans la procédure de fusion mais

également dans l'optimisation des paramètres des modèles combinés. Il est à souligner que les AGs adoptés dans les travaux cités précédemment sont sélectionnés essentiellement pour l'optimisation des paramètres des modèles considérés pour l'agrégation. Alors que dans notre cas, on s'intéresse davantage à la structure de chromosome modélisant la meilleure configuration possible de fusion. De plus, le chromosome est proposé pour l'affectation des meilleurs poids aux régresseurs en compétition.

4.3 Vue d'ensemble des techniques adoptées

Dans cette section, nous présentons les principales techniques adoptées dans notre approche hybride proposée, notamment les AG, le GPR et l'ANFIS. Dans la stratégie élaborée, on a opté pour une approche intégrée avec le choix de l'AG comme technique de fusion et les deux dernières méthodes pour la modélisation des prédicteurs à fusionner, qui sont de nature différente en terme de traitement de données. En effet, le GPR est basé sur l'utilisation d'une distribution préalable caractérisant le problème à modéliser tandis que l'ANFIS est basé sur un réseau adaptatif exprimé par un système d'inférence neuro-flou pour manipuler les données d'entrées.

4.3.1 Algorithmes génétiques

Un AG est une métaheuristique proposée en 1992 par J.H. Holland pour imiter le processus d'évolution biologique dans la nature. La représentation du chromosome, les opérateurs inspirés de la biologie et la sélection sont les principaux éléments de la technique [16]. Le chromosome représente une solution et les paramètres correspondants sont représentés par des gènes. À l'aide d'une fonction objectif, les solutions ou individus candidats sont évalués et les meilleures solutions sont sélectionnées aléatoirement proportionnellement à la valeur de sa fonction objectif. Les mauvaises solutions ont également une probabilité de sélection, ce qui augmente l'évitement des optima locaux [17]. Dans ce qui suit, nous présentons les éléments de base des AGs.

4.3.1.1 Éléments de l'AG

Dans cette partie, nous présentons les éléments fondamentaux des algorithmes génétiques, notamment la formulation de la population initiale, l'évaluation, la sélection, les concepts de croisement et de mutation.

■ Population initiale (génération de solutions candidates)

Un ensemble de solutions candidates est généré au début de la procédure de recherche, qui représente un sous-ensemble de l'espace des solutions. Les solutions formant la population initiale peuvent être construites de manière aléatoire ou à l'aide d'outils de génération heuristique dédiés [18].

■ Évaluation

Dans cette phase, les solutions sont évaluées en attribuant une valeur d'adéquation à l'aide d'une fonction objectif. Dans certaines applications, d'autres procédures sont nécessaires, telles que des fonctions d'échelle et de pénalité [18].

■ Sélection pour la reproduction

Les individus ayant un bon score de fitness sont sélectionnés pour la reproduction afin de constituer la prochaine génération de la population. La procédure de sélection peut être réalisée de manière déterministe, stochastique comme la sélection par roulette ou mixte comme la sélection par classement [19]. La sélection de Boltzmann, la sélection par tournoi, la sélection par rang, la sélection en régime permanent, la sélection par troncature et la sélection locale sont d'autres méthodes de sélection disponibles [17].

- **Croisement (Recombinaison)** Les chromosomes sélectionnés sont combinés pour générer de nouveaux individus appelés solutions enfants [17]. Sur la base du codage génétique, la technique de croisement peut être réalisée sur des positions à un point, deux points, multipoints ou uniformes [19]. La figure 4.2 met en évidence les techniques de croisement couramment rencontrées.




FIGURE 4.2 – Opérateurs de croisement largement utilisés

■ Mutation

Contrairement à l'opérateur de croisement dans lequel nous utilisons deux parents pour réaliser cette procédure, nous n'avons besoin que d'un seul individu dans la phase de mutation pour générer une descendance. Dans cette étape, la position aléatoire d'un parent sélectionné au hasard est considérée pour la fonction de mutation. La mutation peut être réalisée en une seule position ou en plusieurs, ce qui peut être assuré par des suppressions, des substitutions ou des insertions [19]. D'autres techniques de mutation sont introduites dans la littérature, à savoir la mutation de puissance, la mutation gaussienne et la mutation supervisée [17]. Certaines opérations de mutation extraites de la littérature sont illustrées sur la figure 4.3 [19].

La procédure d'optimisation de l'AG commence par une population initiale aléatoire d'individus. La population initiale est améliorée en utilisant les opérateurs mentionnés ci-dessus et donne une nouvelle population avec des solutions améliorées. La procédure est répétée jusqu'à ce que la meilleure solution souhaitée soit obtenue ou que la valeur du critère final soit atteinte. Le taux de sélection, la probabilité de croisement et la probabilité de mutation sont des valeurs définies par l'utilisateur et peuvent être fixées au début ou modifiées au cours de la procédure d'optimisation. La meilleure solution finale est retournée une

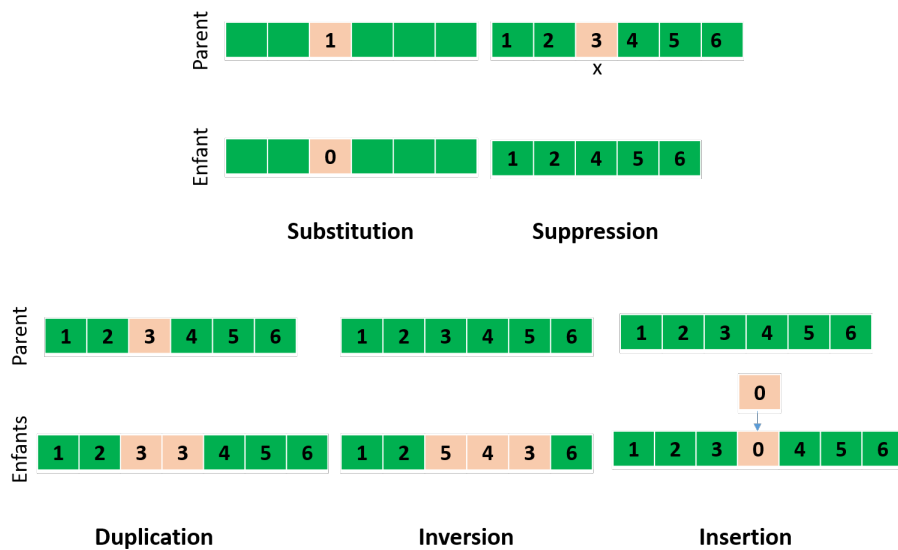


FIGURE 4.3 – Illustration de quelques procédures de mutation

fois l'optimisation terminée en se référant à l'historique des valeurs de la fonction objectif associées à toutes les populations [17]. Le pseudo-code de l'algorithme génétique standard est présenté par l'algorithme 4.1 [16].

Algorithm 4.1: Algorithme génétique classique

Entrée : Taille de la population : n ; Nombre de générations : $ngen$
Sortie : Meilleure solution : S_{best}

Début :

Générer la population initiale avec n chromosomes
de $gen = 1$ à $ngen$ **faire**
 Calculer la valeur objective de chaque chromosome
 Sélectionner les chromosomes candidats pour la reproduction
 Appliquer l'opérateur de croisement
 Appliquer la procédure de mutation
 Remplacer l'ancienne population par la nouvelle population générée

fin

Retourner la meilleure solution S_{best}

Fin

4.3.1.2 Variantes de l'AG

Différents types de modèles d'AG ont été proposés et étudiés dans la littérature. Dans ce qui suit, nous décrivons un ensemble de techniques d'AG populaires [16] :

- AG à codage réel et binaire ;
- AG multiobjectif, y compris l'AG multiobjectif basé sur Pareto et l'AG multiobjectif basé sur la décomposition ;

- AG parallèles, notamment les AG parallèles maître-esclave, les AG parallèles à grain fin et les AG parallèles à grain grossier ;
- AG chaotiques ;
- AG hybrides.

En outre, différents types d'opérateurs sont utilisés pour conduire l'implémentation des AGs. Nous reprenons dans la figure 4.4 les différentes classes d'opérateurs exploitées dans le contexte des AGs [16].

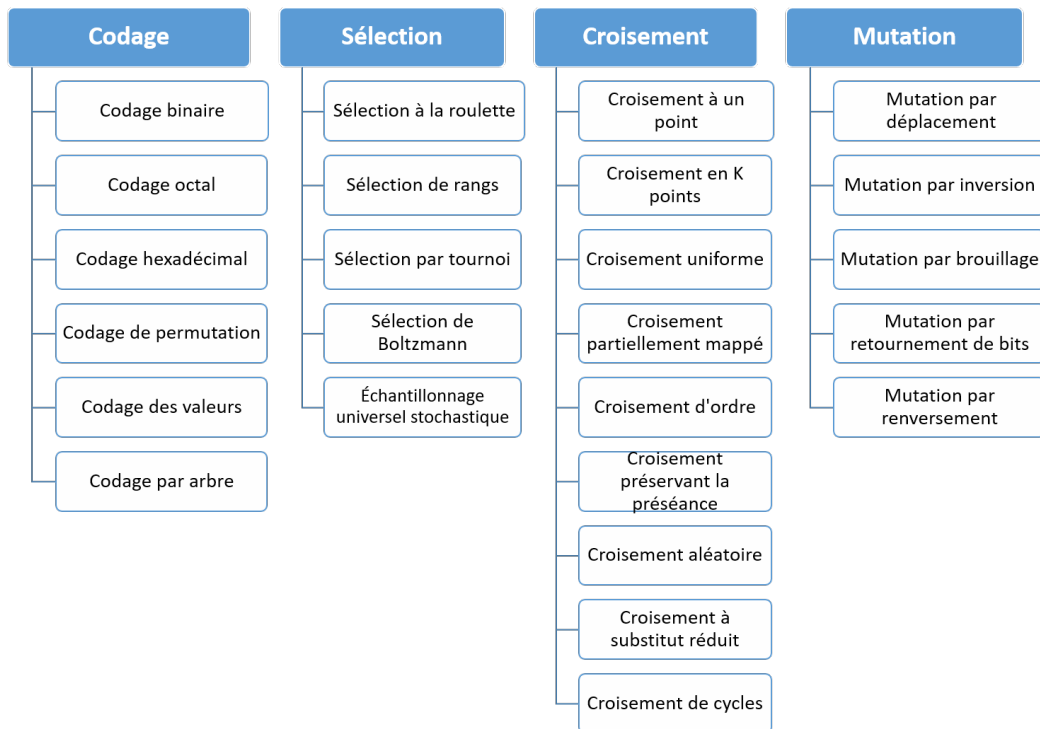


FIGURE 4.4 – Liste récapitulative de quelques opérateurs d'algorithmes génétiques

Comme tout algorithme d'optimisation, l'AG a ses propres avantages et limites. Certains des points importants et des avantages de l'AG sont [20, 21] :

- Simplicité de l'approche ;
- Convient aux variables continues ou discrètes ;
- Ne nécessite pas le calcul du gradient de la fonction objectif ;
- Recherche simultanée à partir d'un grand échantillon distribué sur l'espace de solution ;
- Convient à un grand nombre de variables ;
- Peut être adopté dans des ordinateurs parallèles ;
- Offre de multiples solutions optimales ;
- Peut manipuler des données expérimentales ou numériques et des fonctions analytiques ;

- Réponse robuste à des circonstances variables.

Outre les avantages susmentionnés, nous pouvons distinguer certaines limites comme indiqué ci-dessous [22] :

- Convergence lente par rapport à d'autres méthodes d'optimisation ;
- Moins efficace par rapport aux méthodes traditionnelles dans le cas de problèmes très simples ;
- Convergence vers différentes solutions proches de l'optimal, même en exécutant à plusieurs reprises avec les mêmes paramètres (comportement stochastique).

4.3.2 Régression par processus gaussien

Le processus gaussien (GP) est considéré comme l'une des principales techniques bayésiennes non paramétriques d'apprentissage automatique basées sur l'utilisation d'une distribution préalable sur une fonction. Mathématiquement, un GP est équivalent à de nombreuses méthodes populaires sous certaines conditions, comme les modèles linéaires bayésiens, les réseaux neuronaux et les machines à vecteurs de support. Par rapport aux approches conventionnelles telles que les réseaux neuronaux, un modèle GP est plus facile à modéliser et à interpréter [23]. Il est entièrement défini par deux éléments importants, la fonction moyenne et le second élément connu sous le nom de fonction de covariance, qui est l'ingrédient crucial du modèle GP. Analytiquement, il est défini par l'équation 4.1 :

$$f(x) \sim GP(m(x), k(x, x')) \quad (4.1)$$

où $m(x)$ et $k(x, x')$ désignent respectivement la fonction moyenne et la fonction de covariance, définies par les équations 4.2 et 4.3

$$m(x) = E[f(x)] \quad (4.2)$$

et

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (4.3)$$

Le problème d'apprentissage d'un GP consiste à attribuer des valeurs admissibles aux paramètres de la fonction moyenne et de la fonction de covariance appelés hyper-paramètres. Ces paramètres libres doivent être réglés à l'aide des données d'apprentissage fournies en maximisant la vraisemblance marginale définie comme suit :

$$\log(y|X, \theta) = -\frac{1}{2}y^T(K + \sigma_{ns}^2 I)^{-1}y - \frac{1}{2}\log(|K + \sigma_{ns}^2 I|) - \frac{nt}{2}\log(2\pi) \quad (4.4)$$

où θ et nt désignent respectivement le vecteur associé des hyperparamètres et la taille de l'ensemble de données d'apprentissage. Le paramètre I décrit la matrice unitaire de dimension nt .

4.3.3 ANFIS : Système d'inférence flou basé sur un réseau adaptatif (Adaptive-Network-Based Fuzzy Inference System)

Le calcul souple et neuro-flou est une discipline qui englobe deux visions complémentaires avec certaines techniques d'optimisation. Elle vise à intégrer les réseaux neuronaux, qui peuvent reconnaître efficacement des modèles inconnus ainsi que la capacité de s'adapter aux changements de l'environnement, avec les systèmes d'inférence flous ayant la capacité d'interpréter les connaissances humaines et d'inférer les décisions [24]. Dans le cadre des réseaux adaptatifs, ANFIS ou système d'inférence flou, basé sur un réseau adaptatif est un système d'inférence neuro-flou proposé en 1993 par Jang et al [25]. Le modèle ANFIS peut construire un ensemble de règles floues sous la forme de règles si-alors et générer des paires entrée-sortie stipulées en utilisant des fonctions d'appartenance adéquates. Un modèle ANFIS est une fusion de l'apprentissage/robustesse du réseau neuronal et de la lisibilité/interprétabilité des systèmes flous [26].

4.3.3.1 Architecture de l'ANFIS

Un modèle standard d'ANFIS est défini comme un simple système d'inférence floue de Takagi et Sugeno avec deux règles dans la base de règles. Dans cette architecture, deux entrées x et y et une sortie z sont considérées, où les deux règles sont définies par [25] :

Règle 1 : Si x est A_1 et y est B_1 , alors $f_1 = p_1x + q_1y + r_1$;

Règle 2 : Si x est A_2 et y est B_2 , alors $f_2 = p_2x + q_2y + r_2$;

où A et B sont les variables linguistiques de la fonction d'appartenance considérée. p , q et r sont les paramètres inconnus de la fonction polynomiale conséquent du premier ordre, qui seront réglés pendant la phase d'apprentissage. Dans la figure 4.5, nous présentons l'architecture ANFIS dans la partie inférieure et le modèle de raisonnement de Sugeno correspondant dans la partie supérieure.

Les nœuds des mêmes couches ont des fonctions d'appartenance similaires, comme décrit ci-après [25] :

Couche 1 : Les nœuds de cette couche sont des carrés avec une fonction de nœud

$$O_{1,i} = \mu_{A_i}(x) \quad (4.5)$$

où O est la fonction d'appartenance associée au nœud i qui spécifie le degré de satisfaction du quantificateur A_i . x et A sont respectivement l'entrée et le label linguistique.

Couche 2 : Chaque nœud de cette couche est de type cercle et envoie le produit des signaux entrants qui représente la force d'amorçage d'une règle définie par l'équation 4.6

$$O_{2,i} = \mu_{A_i}(x) \times \mu_{B_i}(y), i = 1, 2 \quad (4.6)$$

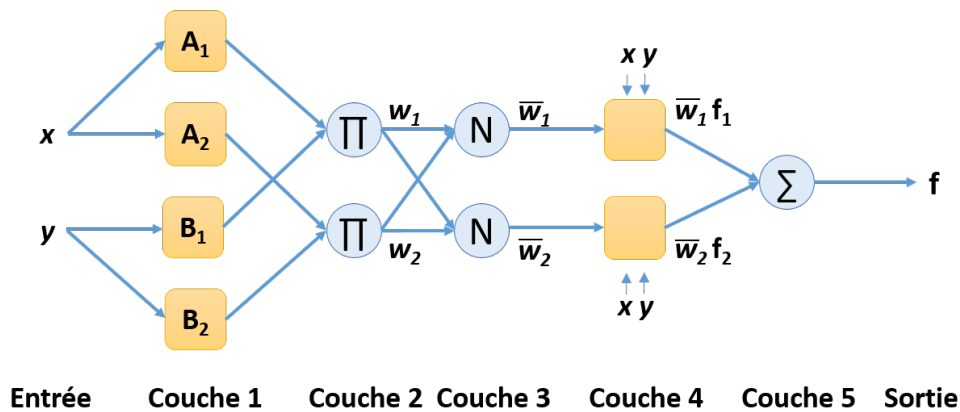



FIGURE 4.5 – Architecture ANFIS (en bas) et modèle flou équivalent de Sugeno de premier ordre à deux entrées avec deux règles (en haut)

Couche 3 : Les nœuds de cette couche sont étiquetés N et sont des nœuds de cercles. Le $i^{ème}$ nœud est réservé au calcul du rapport entre le poids de la $i^{ème}$ règle et la somme des poids de toutes les règles

$$O_{3.i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \tag{4.7}$$

Le résultat obtenu de cette couche est appelé *poids normalisés*.

Couche 4 : Les nœuds de cette couche sont adaptatifs avec l'équation 4.8.

$$O_{4.i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \tag{4.8}$$

où \bar{w}_i est la sortie de la couche 3. p_i, q_i et r_i sont les paramètres de ce nœud appelés paramètres conséquents.

Couche 5 : Cette couche comporte un seul nœud servant à calculer la somme de tous les signaux entrants. Ce nœud est un nœud circulaire étiqueté Σ .

$$O_{5.i} = overall_output = \sum \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \tag{4.9}$$

4.3.3.2 Algorithme d'apprentissage ANFIS

L'algorithme d'apprentissage d'ANFIS est basé sur une méthode d'apprentissage hybride utilisant le passage avant et arrière comme indiqué dans le tableau 4.1. Dans le passage avant, les signaux fonctionnels avancent jusqu'à la quatrième couche où la méthode des moindres carrés est désignée pour estimer les paramètres conséquents. Les taux d'erreur sont propagés vers l'arrière dans le passage arrière où l'approche de descente de gradient est utilisée pour mettre à jour les paramètres conséquents [25].

TABLE 4.1 – Deux passages de la procédure d'apprentissage hybride d'ANFIS

	Passage avant	Passage arrière
Paramètre de fonction d'appartenance	Fixé	Descente de Gradient
Paramètre de coefficient	Moindres carrés	Fixé
Signaux	Sorties des nœuds	Taux d'erreur

4.4 Cadre de l'approche hybride proposée

Dans cette section, nous présentons les principales étapes du modèle de pronostic génétique hybride proposé, de la phase d'initialisation à la phase finale, qui est la prédiction de la durée de vie utile restante. Nous pouvons considérer que notre approche proposée implique trois phases principales, l'initialisation des paramètres et la préparation des données, l'apprentissage des modèles et l'optimisation de l'AG et enfin la phase de prédiction. La figure 4.6 illustre les principales phases du modèle hybride de pronostic proposé.

4.4.1 Initialisation des paramètres et préparation des données

Initialisation des paramètres

Nous entendons par paramètres initiaux dans cette phase, les paramètres initiaux des prédicteurs sélectionnés pour réaliser la phase de prédiction. En outre, le nombre de prédicteurs, les types de prédicteurs, le rapport entre les données d'apprentissage et de validation adoptées sont définis lors de cette phase.

Spécifications des paramètres génétiques

À ce niveau, nous définissons tous les paramètres nécessaires pour lancer le processus d'optimisation de l'AG. Par exemple, le ratio de sélection, la probabilité de croisement et la probabilité de mutation sont définies par l'utilisateur à ce stade. La taille de la population, le nombre d'itérations ou le critère d'arrêt sont d'autres paramètres génétiques qui seront définis avant de passer à l'étape suivante.

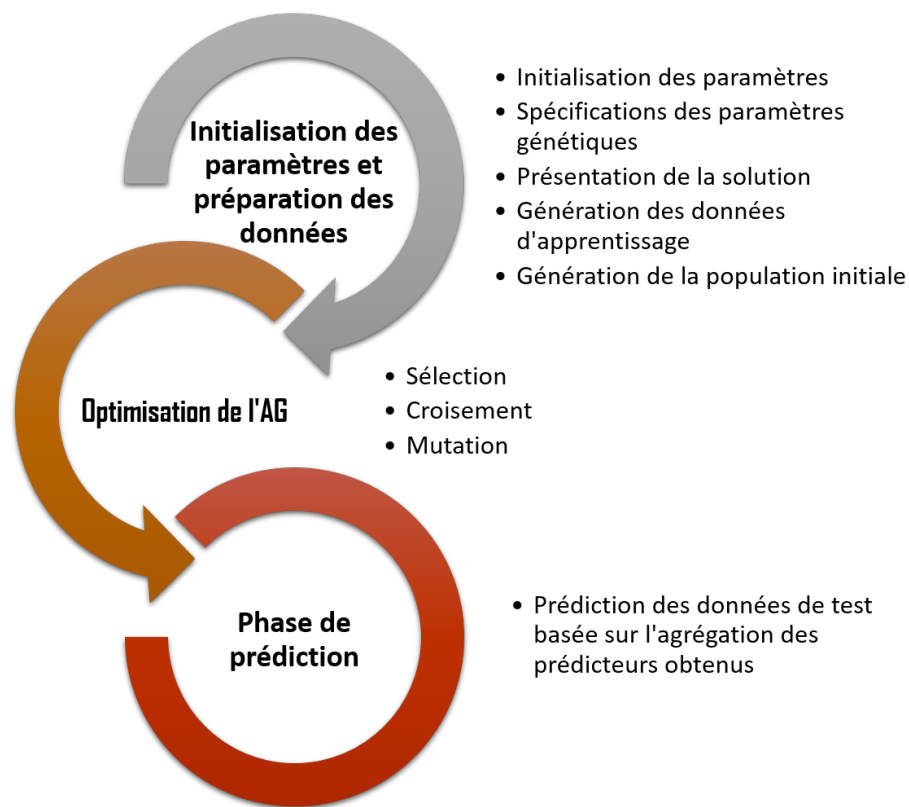


FIGURE 4.6 – Etapes principales de l'approche proposée

Présentation de la solution

Le succès de toute méthode d'AG repose sur son composant clé, à savoir les schémas de codage appelés représentation de la solution. Dans la figure 4.7, nous présentons un exemple de notre proposition de chromosome ou de solution.

Comme le montre la figure 4.7, la taille de chromosome proposée est une matrice de $3 \times n$ dans laquelle la première ligne sert à indiquer le type de régresseur adopté. La deuxième et troisième ligne sont réservées à l'attribution d'un poids approprié et de paramètres adéquats respectivement pour chaque prédicteur. Nous entendons par paramètres dans cette solution toutes les méthodes, fonctions et paramètres des prédicteurs.

Génération des données d'apprentissage

Après avoir défini tous les paramètres initiaux nécessaires, nous formulons nos données d'apprentissage et de test sous une forme appropriée pour chaque type de prédicteurs. En fonction du prédicteur choisi, les données d'entrée peuvent être utilisées sous forme brute ou de séries temporelles et peuvent nécessiter d'autres procédures telles que la phase d'extraction des caractéristiques. Dans notre cas, nous transformons nos données en gradient comme nous l'avons fait dans nos contributions précédentes (voir chapitre 2 et chapitre 3).

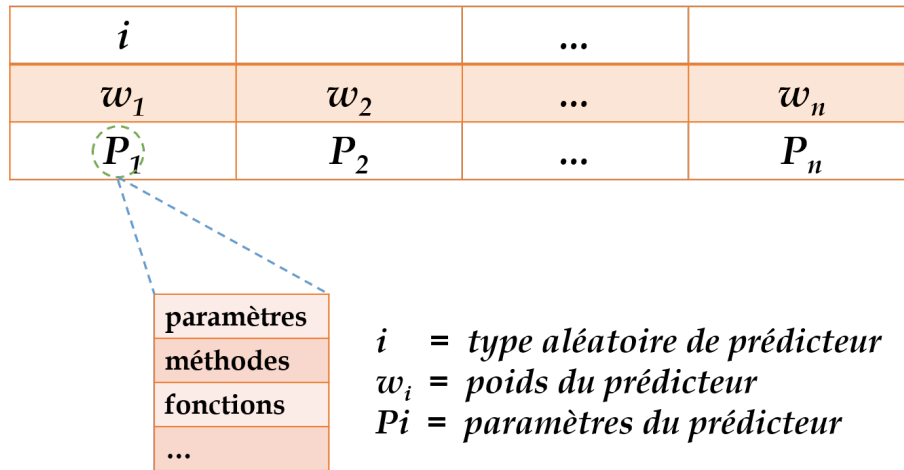


FIGURE 4.7 – Architecture proposée pour le codage du chromosome (solution)

Génération de la population initiale

En utilisant les paramètres génétiques initiaux définis dans la phase précédente, une population initiale est générée avec des valeurs aléatoires. Le résultat est une matrice de dimension $3 \times n \times l$, où n et l sont le nombre de prédicteurs adoptés et la taille de la population respectivement. Un exemple de population est fourni dans la figure 4.8 pour donner au lecteur un aperçu de la population GA proposée.

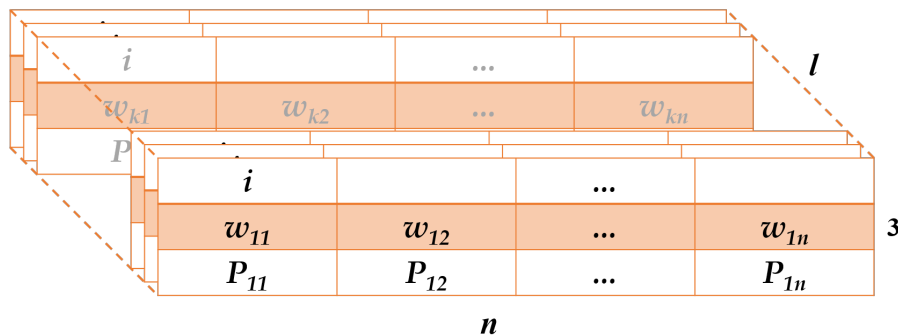


FIGURE 4.8 – Architecture de la population proposée

A ce niveau, on peut considérer que toutes les entrées nécessaires pour exécuter l'étape d'optimisation de l'AG et accomplir la phase de prédiction sont définies.

4.4.2 Optimisation de l'AG

Notre travail dans cette partie est l'exécution de la procédure d'optimisation génétique comprenant la sélection, le croisement et la mutation comme illustré par les sous-programmes suivants.

Sélection

Dans cette étape, une fonction objectif est utilisée pour évaluer tous les individus de la population et parmi les méthodes de sélection existantes, une procédure de sélection est choisie pour sélectionner un ensemble d'individus appropriés pour la reproduction dans l'étape suivante. Les principales étapes de la fonction objectif proposée sont décrites dans l'algorithme 4.2.

Algorithm 4.2: Fonction objectif proposée

Entrée : *Solution, wt*

Sortie : *Valeur_objective*

Début :

pour prédicteur $i = 1$ à prédicteur n **dans** Solution

Entraîner le prédicteur i

Calculer l'erreur d'apprentissage $etrain_i$ de prédicteur i

Calculer l'erreur de validation $eval_i$ de prédicteur i

Calculer l'erreur pondérée : $E_i = wt \times etrain_i + (1 - wt) \times eval_i$

fin

$Valeur_objective = \sum_{i=1}^n (w_i \times E_i)$

Fin

Le poids wt est une valeur définie par l'utilisateur introduite pour faire la moyenne pondérée des erreurs d'apprentissage et de validation. w_i est le poids affecté à chaque prédicteur.

L'objectif de notre AG est la minimisation de la somme pondérée des erreurs pondérées obtenues et l'association d'un poids à chaque prédicteur. Les poids sont affectés aux prédicteurs en valeurs aléatoires avec leur somme égale à 1 dans la population initiale.

Croisement

Le croisement ou la reproduction est une phase obligatoire introduite pour générer une nouvelle génération de solutions en utilisant les individus sélectionnés. Dans ce travail, trois types de stratégies de croisement sont proposés, un point, deux points et une stratégie hybride dans laquelle une sélection aléatoire de l'une de ces stratégies est choisie à chaque génération d'un enfant. Les deux stratégies de croisement adoptées sont précisées dans la figure 4.2. En appliquant la procédure de croisement, les deux enfants résultants ont des poids non normalisés (somme non égale à 1) donc une procédure de normalisation est nécessaire à ce niveau. Nous avons choisi de diviser les poids par la somme des poids obtenus dans les nouveaux enfants.

Mutation

La procédure de mutation est introduite pour générer de nouvelles solutions en changeant une position aléatoire dans chaque chromosome sélectionné au hasard. Dans la méthode proposée, nous avons choisi de réentraîner le prédicteur de la position candidate à

la mutation après avoir sélectionné de nouvelles propriétés et de nouveaux paramètres initiaux.

Les phases sélection, croisement et mutation, sont répétées jusqu'à ce que le critère d'erreur soit atteint ou jusqu'à la fin du nombre d'itérations défini pour l'algorithme génétique développé. Le résultat de cette phase est la meilleure solution ayant la meilleure fonction objectif.

4.4.3 Phase de prédiction

Une fois que nous avons obtenu la meilleure solution, c'est-à-dire un individu avec n prédicteurs ayant ensemble la meilleure erreur de fusion (apprentissage et validation), nous prédisons les données de test en utilisant les n prédicteurs obtenus, ce qui donne n sorties représentant les données de test prédites. Les résultats obtenus sont fusionnés en utilisant une procédure de moyenne pondérée basée sur les poids inclus dans la meilleure solution.

L'algorithme 4.3 explique comment réaliser cette phase de fusion.

Algorithm 4.3: Prédiction

Entrée : *Meilleure_solution*

Sortie : Durée de vie utile restante RUL

Début :

pour prédicteur $i = 1$ à prédicteur n **dans** *Meilleure_solution*

Prédire les données de test $P_{test}(i)$ en utilisant Prédicteur i

fin

Appliquer la procédure d'agrégation : $fused_test_data = W^T P_{test}$

Conversion en données originales

Estimer le RUL et calculer l'erreur de test

Fin

L'algorithme de conversion des données de gradient prédites en représentation originale a déjà été détaillé au deuxième chapitre.

4.5 Données expérimentales et résultats

Le présent chapitre utilise l'ensemble de données sur les batteries, hébergé par le site du Centre d'excellence en matière de pronostic (PCoE) de la NASA Ames. Un ensemble de quatre batteries lithium-ion (n° 5, 6, 7 et 18) est soumis à trois modes de fonctionnement différents, à savoir la charge, la décharge et l'impédance, à température ambiante. Les batteries sont chargées par un mode de courant constant (CC) à 1.5A jusqu'à atteindre une valeur de tension de 4.2V, qui caractérise le mode de charge. Ensuite, la tension suit un mode de tension constante (CV) jusqu'à atteindre un courant de charge d'une valeur de 20mA. En mode décharge, un courant constant (CC) de 2A est réservé jusqu'à atteindre des valeurs de tension réduites de 2.7V, 2.5V, 2.2V et 2.5V pour les batteries numérotées 5, 6, 7 et 18, respectivement. Sur la base d'une spectroscopie d'impédance électrochimique changeant de

fréquence dans l'intervalle [0.1Hz : 5kHz], les mesures nécessaires sont réalisées pour porter le mode d'impédance qui est le dernier régime. Une dégradation monotone de la performance des batteries est observée par la répétition des cycles de charge/décharge comme indiqué par les données obtenues, qui offre quelques aperçus concernant les caractéristiques d'évolution du phénomène de vieillissement. Les expériences menées sont arrêtées lorsque le critère de fin de vie (EoL) des batteries est atteint, ce qui est défini par une réduction de 30% de la capacité nominale (de 2Ahr à 1.4Ahr) [27].

Parmi les méthodes existantes d'estimation de l'état de santé (SOH) associées à l'indicateur de l'état des batteries lithium-ion utilisé dans le pronostic et la gestion de l'état (PHM) des batteries, le SOH de la batterie basé sur la capacité est mis en œuvre dans ce travail et est exprimé par :

$$SOH = \frac{C_i}{C_0} \times 100\% \quad (4.10)$$

où C_i désigne la $i^{\text{ème}}$ grandeur de capacité dégradée avec les cycles et C_0 représente la capacité initiale [28].

Les données de la batterie 5 sont sélectionnées à des fins d'apprentissage et de test dans cette expérience. Dans la figure 4.9, nous traçons le critère SOH des quatre batteries utilisées dans les expériences pour donner un aperçu du comportement de dégradation de ces batteries.




FIGURE 4.9 – Evolution du critère SOH des batteries en fonction du nombre de cycles

Dans la figure 4.10, nous montrons la valeur SOH allant du cycle 1 au cycle 168, y compris l'ensemble de données d'apprentissage, de validation et de test représenté par $Y_{train} = \{t, SOH(t)\}_{t=1}^{70}$, $Y_{val} = \{t, SOH(t)\}_{t=71}^{100}$ et $Y_{test} = \{t, SOH(t)\}_{t=101}^{168}$, respectivement.




FIGURE 4.10 – Illustration de la mesure SOH de la batterie n° 5, y compris les régions d'apprentissage, de validation et de test

Pour la construction de l'approche pronostique hybride, nous avons choisi de prendre la régression par processus gaussien et les modèles ANFIS comme principaux prédicteurs. Dans ce qui suit, nous montrons étape par étape l'élaboration de la méthode hybride de pronostic proposée à base d'algorithme génétique.

4.5.1 Initialisation des paramètres et préparation des données

Initialisation des paramètres

Considérons la notation donnée des paramètres utilisés dans ce travail et les fonctions comme indiqué dans le tableau 4.2.

Les fonctions de covariance utilisées pour les modèles GPR sont définies comme indiqué ci-dessous :

$$Cov1 = \sigma^2 \exp \left(-\frac{2}{l^2} \sin^2 \left(\frac{w}{2\pi} (x_i - x_j) \right) \right) + \sigma^2 \exp \left(-\frac{(x_i - x_j)^2}{2l^2} \right) \quad (4.11)$$

$$Cov2 = \sigma^2 \exp \left(-\frac{2}{l^2} \sin^2 \left(\frac{w}{2\pi} (x_i - x_j) \right) \right) + \sigma^2 \delta_{ij} \quad (4.12)$$

où σ_{ij} est la fonction delta de Kronecker.

TABLE 4.2 – : Notations et valeurs des paramètres et fonctions adoptés

Paramètre	Valeur	Définition
Paramètres généraux		
<i>i</i>	0 :GPR, 1 : ANFIS	Type de prédicteur
<i>n</i>	5	Nombre de prédicteurs
<i>l</i>	50	Taille de la population (nombre de chromosomes)
<i>wt</i>	0.7	Poids de l'erreur d'apprentissage
<i>ratioselect</i>	0.3	Taux de sélection
<i>Crossprob</i>	0.8	Probabilité de croisement
<i>Mutprob</i>	0.1	Probabilité de mutation
Paramètres des modèles GPR		
<i>gpr_itr</i>	2000	Nombre d'itérations pour GPR
<i>meanf</i>	[]	Fonction de moyenne
<i>covf</i>	Cov1, Cov2	Fonction de covariance
<i>lik</i>	'likGauss'	Fonction de vraisemblance
<i>infer</i>	'infExact'	Méthode d'inférence
Paramètres des modèles ANFIS		
<i>fis_itr</i>	300	Nombre d'itérations de l'ANFIS
<i>InputMFTtype</i>	'gaussmf'	Fonction d'appartenance d'entrée de l'ANFIS
<i>p</i>	Valeur aléatoire	Période de l'ANFIS
ANFIS type	Sugeno	Type de l'ANFIS
ANFIS structure	<i>GridPartition</i>	Structure de l'ANFIS

Génération des données d'apprentissage

Nous utilisons les 100 premiers cycles pour l'apprentissage où nous choisissons de considérer 70 et 30 cycles pour l'apprentissage et la validation, respectivement. Comme le modèle GPR est un modèle non paramétrique, nous utilisons le numéro de cycle et la valeur SOH correspondante comme entrées. Pour le cas ANFIS, nous utilisons la valeur SOH et nous préparons les données sous forme de séries temporelles basées sur la période sélectionnée pour chaque prédicteur (en phase d'apprentissage). Avant de préparer les données d'apprentissage sous une forme appropriée pour chaque régresseur, une transformation des données en valeurs de gradient a été effectuée.

Génération de la population initiale

Une matrice de taille $3 \times 5 \times 50$ est construite pour exprimer la population initiale avec 50 chromosomes ou solutions initiales. Une illustration d'une solution est présentée dans la figure 4.11.

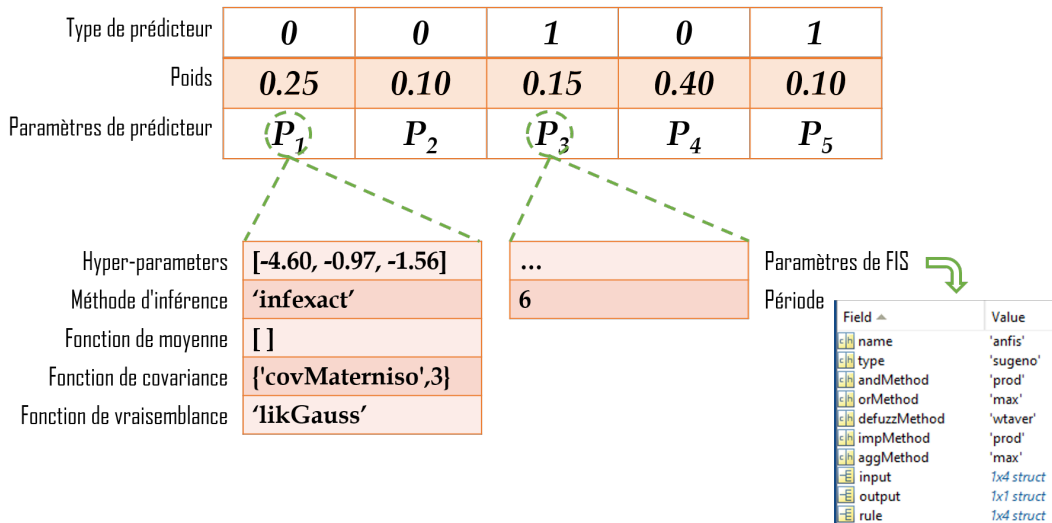


FIGURE 4.11 – Exemple d'un échantillon de chromosome

4.5.2 Optimisation de l'AG

La phase d'optimisation génétique comporte trois étapes principales : la sélection, le croisement et la mutation. Dans notre cas, nous considérons 0.3 comme ratio de sélection en utilisant la stratégie de sélection par roulette. Pour l'opérateur de croisement, nous choisissons de prendre une valeur 0.8 comme probabilité de croisement. Une stratégie de croisement d'un point ou de deux points est adoptée par sélection aléatoire de l'opérateur à chaque génération d'un enfant. Après avoir terminé le processus de croisement et que tous les enfants ou nouvelles solutions sont générés, nous passons à l'étape suivante qui est la procédure de mutation. Tout nouveau chromosome a une certaine probabilité de subir une opération de mutation qui est choisie égale à 0.1 dans notre application. Comme nous l'avons indiqué dans la présentation théorique, nous réentraînon le prédicteur de la position candidate à la mutation en sélectionnant de nouvelles propriétés et de nouveaux paramètres initiaux. Par exemple, si le point sélectionné pour la mutation est un prédicteur GPR, nous définissons de nouveaux hyper paramètres et nous réentraînon le nouveau modèle GPR obtenu. La même opération est recommandée si une position de mutation contient un modèle ANFIS, nous réentraînon l'ANFIS avec de nouveaux paramètres et une nouvelle période.

4.5.3 Phase de prédiction

A ce niveau, nous avons obtenu la meilleure solution en terminant la procédure d'optimisation de l'AG après 50 générations résultant de 50 itérations. La figure 4.12 montre la meilleure solution obtenue en appliquant l'algorithme proposé à la batterie 5.

Cette figure révèle que tous les prédicteurs sélectionnés pour l'agrégation dans la meilleure solution sont des modèles GPR avec presque les mêmes méthodes et fonctions mais avec des hyperparamètres différents. Nous observons qu'aucun modèle ANFIS n'est sélectionné dans cette solution en raison de sa mauvaise qualité de prédiction.

Cette meilleure solution est obtenue de 50 populations après 50 itérations, comme le montre la figure 4.13.

Type de prédicteur	0	0	0	0	0
Poids	0.2716	0.1723	0.1976	0.1894	0.1691
Paramètres de prédicteur	P_1	P_2	P_3	P_4	P_5
	P_1	P_2	P_3	P_4	P_5
Hyper-parameters	hyp1	hyp2	hyp3	hyp4	hyp5
Méthode d'inférence	'infexact'	'infexact'	'infexact'	'infexact'	'infexact'
Fonction de moyenne	[]	[]	[]	[]	[]
Fonction de covariance	Cov1	Cov1	Cov1	Cov1	Cov2
Fonction de vraisemblance	'likGauss'	'likGauss'	'likGauss'	'likGauss'	'likGauss'

FIGURE 4.12 – Meilleure solution obtenue pour la batterie 5




FIGURE 4.13 – Valeur de la fonction objectif en fonction du nombre d'itérations, appliquée à la batterie 5

Les résultats de prédiction obtenus par le modèle de pronostic proposé appliqué à la batterie 5 sont illustrés dans la figure 4.14.

Nous observons sur la figure 4.14 que la prédiction basée sur la méthode de pronostic proposée explique avec suffisamment de précision l'évolution de la mesure SOH et les variations connues sous le nom de phénomène d'auto-recharge sont également capturées. Dans la figure 4.15, nous illustrons le résultat de fusion ainsi que les sorties obtenues fournis par les prédicteurs sélectionnés pour la fusion.

Nous percevons clairement dans cette figure que la plupart des résultats fournis par les prédicteurs sélectionnés par l'AG proposé reflètent de manière satisfaisante l'évolution du SOH réel. Nous pouvons déduire de cette observation que l'approche proposée fournit non seulement des résultats de fusion satisfaisants mais sélectionne également des prédicteurs prometteurs.

Pour valider l'approche hybride proposée de pronostic, nous appliquons la même technique aux autres batteries restantes (6, 7 et 18). Les mesures de SOH prédites obtenues pour

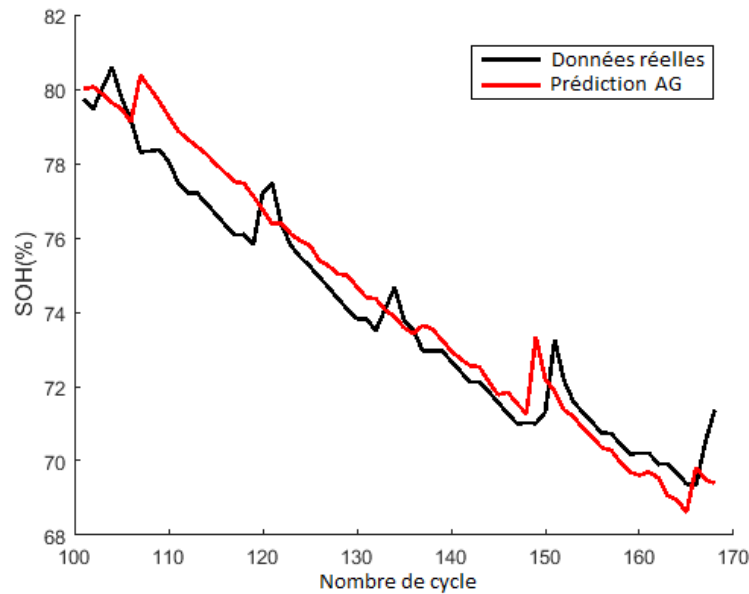


FIGURE 4.14 – Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 5




FIGURE 4.15 – Comparaison des prédicteurs sélectionnés et du résultat de la fusion correspondante

ces batteries sur la base de l'approche proposée sont illustrées dans les figures 4.16 , 4.17 et 4.18, respectivement.

Pour l'évaluation quantitative du cadre proposé, nous avons choisi d'utiliser l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne en pourcentage (MAPE) pour effectuer cette comparaison, comme le montre le tableau 4.3. La RMSE et la MAPE sont définies analytiquement par les équations 4.13 et 4.14.




FIGURE 4.16 – Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 6




FIGURE 4.17 – Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 7

$$RMSE = \sqrt{\frac{\sum_{i=1}^{ntest} (y_i - \hat{y}_i)^2}{ntest}} \quad (4.13)$$

$$MAPE(\%) = \frac{100}{ntest} \sum_{i=1}^{ntest} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4.14)$$

où y_i et \hat{y}_i représentent respectivement les valeurs réelles et estimées, $ntest$ désigne le nombre d'échantillons de test.

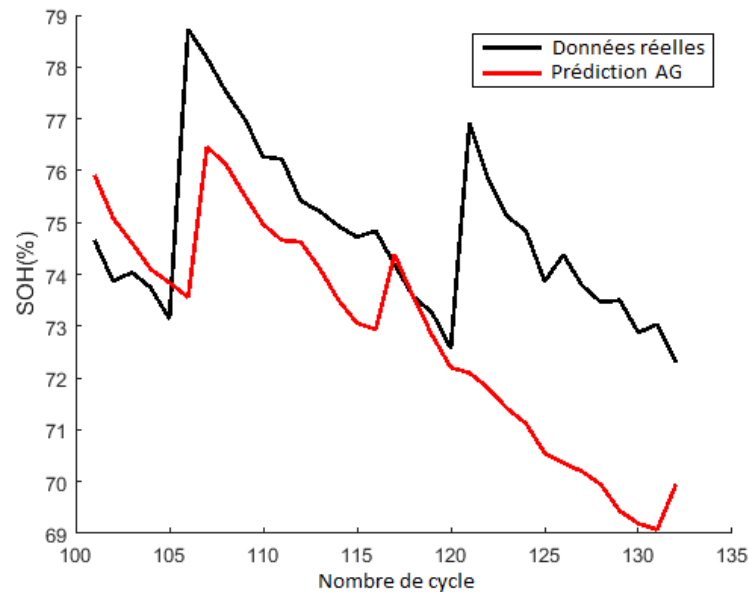


FIGURE 4.18 – Estimation de la mesure SOH basée sur le modèle proposé appliqué à la batterie 18

TABLE 4.3 – Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°5

	Prédicteurs					Fusion
	Prédicteur 1	Prédicteur 2	Prédicteur 3	Prédicteur 4	Prédicteur 5	
Type de prédicteur	GPR	GPR	GPR	GPR	GPR	AG proposée
Poids	0.2716	0.1723	0.1976	0.1894	0.1691	1
RMSE	1.10	1.95	0.94	1.16	1.90	0.89
MAPE (%)	0.85	1.67	0.84	0.85	1.73	0.74

On peut déduire du tableau 4.3 que l'approche de fusion AG proposée donne les meilleurs résultats en termes d'erreur RMSE parmi les prédicteurs sélectionnés pour la fusion. En outre, elle offre les meilleurs résultats en termes de valeur MAPE.

L'analyse quantitative des batteries restantes basée sur la méthode proposée et les cinq prédicteurs sélectionnés par l'AG pour l'agrégation est résumée dans les tableaux 4.4, 4.5, 4.6, respectivement.

TABLE 4.4 – Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°6

	Prédicteurs					Fusion
	Prédicteur 1	Prédicteur 2	Prédicteur 3	Prédicteur 4	Prédicteur 5	
Type de prédicteur	GPR	GPR	GPR	GPR	GPR	AG proposée
Poids	0.2616	0.2180	0.1252	0.2902	0.1049	1
RMSE	2.23	2.41	1.86	2.39	0.86	2.04
MAPE (%)	1.89	2.16	1.53	2.02	0.62	1.74

En analysant les résultats obtenus, nous remarquons que l'approche pronostique AG proposée fournit de bons résultats. De plus, elle offre des résultats satisfaisants pour presque tous les prédicteurs sélectionnés pour la fusion. Il convient de mentionner que les prédicteurs sélectionnés pour l'agrégation sont obtenus à la suite de la méthode AG hybride de

TABLE 4.5 – Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°7

	Prédicteurs					Fusion
	Prédicteur 1	Prédicteur 2	Prédicteur 3	Prédicteur 4	Prédicteur 5	
Type de prédicteur	GPR	GPR	GPR	GPR	GPR	AG proposée
Poids	0.1545	0.3815	0.1714	0.1472	0.1454	1
RMSE	1.00	0.71	0.64	0.74	0.99	0.65
MAPE (%)	0.73	0.52	0.50	0.58	0.72	0.47

TABLE 4.6 – Résultats de prédiction pour les prédicteurs sélectionnés et le modèle de fusion AG appliqués à la batterie n°18

	Prédicteurs					Fusion
	Prédicteur 1	Prédicteur 2	Prédicteur 3	Prédicteur 4	Prédicteur 5	
Type de prédicteur	GPR	GPR	GPR	GPR	GPR	AG proposée
Poids	0.1843	0.1661	0.2618	0.1702	0.2175	1
RMSE	3.84	3.70	2.98	2.30	2.45	2.64
MAPE (%)	3.46	3.31	2.48	1.91	2.08	2.16

pronostic proposée. Nous observons également, bien que la solution de fusion fournisse un résultat satisfaisant dans certains cas, elle n'est pas la meilleure par rapport aux prédicteurs agrégés, comme le montre le tableau 4.4 relatif à la batterie 6.

Nous présentons dans le tableau 4.7 une comparaison de nos résultats avec ceux fournis par certaines contributions de l'état de l'art traitant le même ensemble de données de batteries.

TABLE 4.7 – Comparaison de l'approche proposée et de certains travaux de référence pour les batteries 5, 6, 7 et 18

Réf	Méthode	Batteries			
		Bat 5	Bat 6	Bat 7	Bat18
Liu et al. [28]	Basic GPR	13.03	22.51	20.70	N/A
	LGPFER	1.71	6.90	1.59	N/A
	QGPFR	1.50	5.12	5.52	N/A
	Combination LGPFER	1.36	6.86	1.73	N/A
	Combination QGPFR	1.80	20.44	2.69	N/A
He et al. [29]	SMK-GPR	1.38	7.08	1.88	N/A
	P-MGPR	1.36	2.12	1.14	N/A
	SE-MGPR	1.20	2.11	1.07	N/A
Approche proposée	AG Hybride	0.89	2.04	0.65	2.64

4.6 Conclusion

Dans ce chapitre, nous avons proposé une nouvelle approche hybride de pronostic dans le domaine du PHM, basée sur le paradigme des algorithmes génétiques. Le schéma hybride est basé sur l'agrégation d'un ensemble de prédicteurs par la moyenne pondérée de leurs sorties. Nous avons choisi d'utiliser les méthodes GPR et ANFIS comme modèles candidats

pour réaliser la tâche de prédiction. L'approche de pronostic hybride proposée couvre trois étapes principales, notamment : La définition des données et des paramètres initiaux, l'optimisation de l'AG et enfin la phase de prédiction. Dans la première phase, nous avons préparé nos données sous une forme appropriée pour chaque régresseur où les paramètres nécessaires sont initialisés. Dans la deuxième phase, ces prédicteurs ont été considérés comme des éléments d'une solution génétique proposée, présentée comme un chromosome dont le nombre de colonnes est égale au nombre de prédicteurs. Sur la base de l'erreur d'apprentissage des prédicteurs sélectionnés pour l'agrégation à chaque génération de nouvelle solution, l'algorithme génétique attribue un poids estimé pour chaque prédicteur. La solution finale est un ensemble de prédicteurs ayant en total la meilleure erreur de moyenne pondérée qui est la sortie de la fonction objectif proposée. La dernière étape, appelée phase de prédiction, est introduite pour évaluer les prédicteurs finaux obtenus. Ces prédicteurs ajustés ont été étudiés pour estimer les données de test et agréger les sorties résultantes en utilisant les poids obtenus indiqués dans la meilleure solution. Les tests numériques exploitant les données sur les batteries ont confirmé l'utilité de l'approche AG hybride proposée comme outil compétitif pour la fusion.

Références

1. BAUR, M., ALBERTELLI, P. & MONNO, M. A review of prognostics and health management of machine tools. *The International Journal of Advanced Manufacturing Technology* **107**. Number : 5, 2843-2863. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-020-05202-3> (1^{er} mars 2020).
2. KIM, N.-H., AN, D. & CHOI, J.-H. in *Prognostics and Health Management of Engineering Systems* 1-24 (Springer, Cham, 2017). ISBN : 978-3-319-44740-7 978-3-319-44742-1.
3. ZHANG, W., YANG, D. & WANG, H. Data-Driven Methods for Predictive Maintenance of Industrial Equipment : A Survey. *IEEE Systems Journal* **13**. Conference Name : IEEE Systems Journal, 2213-2227. ISSN : 1937-9234 (sept. 2019).
4. LI, R., VERHAGEN, W. J. C. & CURRAN, R. A systematic methodology for Prognostic and Health Management system architecture definition. *Reliability Engineering & System Safety* **193**, 106598. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832018315084> (1^{er} jan. 2020).
5. MONTERO-JIMENEZ, J. J., SCHWARTZ, S., VINGERHOEDS, R., GRABOT, B. & SALAÜN, M. Towards multi-model approaches to predictive maintenance : A systematic literature survey on diagnostics and prognostics. *Journal of Manufacturing Systems* **56**, 539-557. ISSN : 0278-6125. <http://www.sciencedirect.com/science/article/pii/S0278612520301187> (1^{er} juill. 2020).
6. LIAO, L. & KÖTTIG, F. 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**, 191-207. ISSN : 0018-9529 (mars 2014).
7. BOUZENITA, M., MOUSS, L.-H., MELGANI, F. & BENTRACIA, T. New fusion frameworks including explicit weighting functions for the remaining useful life prognostics. *Expert Systems with Applications* **189**, 116091. ISSN : 0957-4174. <https://www.sciencedirect.com/science/article/pii/S0957417421014263> (1^{er} mars 2022).

8. ZHANG, X., LU, X., LI, W. & WANG, S. Prediction of the remaining useful life of cutting tool using the Hurst exponent and CNN-LSTM. *The International Journal of Advanced Manufacturing Technology* **112**. Number : 7, 2277-2299. ISSN : 1433-3015. <https://doi.org/10.1007/s00170-020-06447-8> (1^{er} fév. 2021).
9. YAN, L. *et al.* A hybrid method with cascaded structure for early-stage remaining useful life prediction of lithium-ion battery. *Energy* **243**, 123038. ISSN : 0360-5442. <https://www.sciencedirect.com/science/article/pii/S0360544221032874> (15 mars 2022).
10. ARIAS CHAO, M., KULKARNI, C., GOEBEL, K. & FINK, O. Fusing physics-based and deep learning models for prognostics. *Reliability Engineering & System Safety* **217**, 107961. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832021004725> (1^{er} jan. 2022).
11. ZANG, Y., SHANGGUAN, W., CAI, B., WANG, H. & PECHT, M. G. Hybrid remaining useful life prediction method. A case study on railway D-cables. *Reliability Engineering & System Safety* **213**, 107746. ISSN : 0951-8320. <https://www.sciencedirect.com/science/article/pii/S0951832021002775> (1^{er} sept. 2021).
12. LI, X., MA, Y. & ZHU, J. An online dual filters RUL prediction method of lithium-ion battery based on unscented particle filter and least squares support vector machine. *Measurement* **184**, 109935. ISSN : 0263-2241. <https://www.sciencedirect.com/science/article/pii/S0263224121008708> (1^{er} nov. 2021).
13. ZHOU, Y. *et al.* Hybrid genetic algorithm method for efficient and robust evaluation of remaining useful life of supercapacitors. *Applied Energy* **260**, 114169. ISSN : 0306-2619. <https://www.sciencedirect.com/science/article/pii/S0306261919318562> (15 fév. 2020).
14. HAN, X., WANG, Z. & WEI, Z. A novel approach for health management online-monitoring of lithium-ion batteries based on model-data fusion. *Applied Energy* **302**, 117511. ISSN : 0306-2619. <https://www.sciencedirect.com/science/article/pii/S030626192100893X> (15 nov. 2021).
15. XUE, Z., ZHANG, Y., CHENG, C. & MA, G. Remaining useful life prediction of lithium-ion batteries with adaptive unscented kalman filter and optimized support vector regression. *Neurocomputing* **376**, 95-102. ISSN : 0925-2312. <https://www.sciencedirect.com/science/article/pii/S0925231219313426> (1^{er} fév. 2020).
16. KATOCH, S., CHAUHAN, S. S. & KUMAR, V. A review on genetic algorithm : past, present, and future. *Multimedia Tools and Applications* **80**. Number : 5, 8091-8126. ISSN : 1573-7721. <https://doi.org/10.1007/s11042-020-10139-6> (1^{er} fév. 2021).
17. MIRJALILI, S. in *Evolutionary Algorithms and Neural Networks : Theory and Applications* (éd. MIRJALILI, S.) 43-55 (Springer International Publishing, Cham, 2019). ISBN : 978-3-319-93025-1. https://doi.org/10.1007/978-3-319-93025-1_4.
18. GARCÍA-MARTÍNEZ, C., RODRIGUEZ, F. J. & LOZANO, M. in *Handbook of Heuristics* (éd. MARTÍ, R., PARDALOS, P. M. & RESENDE, M. G. C.) 431-464 (Springer International Publishing, Cham, 2018). ISBN : 978-3-319-07124-4. https://doi.org/10.1007/978-3-319-07124-4_28.
19. DU, K.-L. & SWAMY, M. N. S. in *Search and Optimization by Metaheuristics : Techniques and Algorithms Inspired by Nature* (éd. DU, K.-L. & SWAMY, M. N. S.) 37-69 (Springer International Publishing, Cham, 2016). ISBN : 978-3-319-41192-7. https://doi.org/10.1007/978-3-319-41192-7_3.

20. RANDY L, H. & SUE ELLEN, H. *Practical genetic algorithms* ISBN : 978-0-471-67174-9. <http://onlinelibrary.wiley.com/doi/abs/10.1002/0471671746.ch6> (John Wiley & Sons, Ltd, 2003).
21. GARCÍA-MARTÍNEZ, C., RODRIGUEZ, F. J. & LOZANO, M. in *Handbook of Heuristics* (éd. MARTÍ, R., PANOS, P. & RESENDE, M. G.) 1-34 (Springer International Publishing, Cham, 2016). ISBN : 978-3-319-07153-4. https://doi.org/10.1007/978-3-319-07153-4_28-1.
22. GOSSELIN, L., TYE-GINGRAS, M. & MATHIEU-POTVIN, F. Review of utilization of genetic algorithms in heat transfer problems. *International Journal of Heat and Mass Transfer* **52**. Number : 9, 2169-2188. ISSN : 0017-9310. <https://www.sciencedirect.com/science/article/pii/S0017931008006534> (1^{er} avr. 2009).
23. RASMUSSEN, C. E. & WILLIAMS, C. K. I. *Gaussian Processes for Machine Learning* <http://www.gaussianprocess.org/gpml/chapters/RW.pdf> (The MIT Press Cambridge MA, 2006).
24. JANG, J., SUN, C. & MIZUTANI, E. Neuro-Fuzzy and Soft Computing-A Computational Approach to Learning and Machine Intelligence [Book Review]. *IEEE Transactions on Automatic Control* **42**. Conference Name : IEEE Transactions on Automatic Control, 1482-1484. ISSN : 1558-2523 (1997).
25. JANG, J.-S. ANFIS : adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics* **23**. Conference Name : IEEE Transactions on Systems, Man, and Cybernetics, 665-685. ISSN : 2168-2909 (1993).
26. CHEN, B., MATTHEWS, P. C. & TAVNER, P. J. Wind turbine pitch faults prognosis using a-priori knowledge-based ANFIS. *Expert Systems with Applications* **40**, 6863-6876. ISSN : 0957-4174. <http://www.sciencedirect.com/science/article/pii/S0957417413003989> (1^{er} déc. 2013).
27. SAHA, B. & GOEBEL, K. *Battery data set, NASA ames prognostics data repository*. NASA Ames 2007. <http://ti.arc.nasa.gov/project/%20prognostic-data-repository>.
28. LIU, D., PANG, J., ZHOU, J., PENG, Y. & PECHT, M. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression. *Microelectronics Reliability* **53**, 832-839. ISSN : 0026-2714. <http://www.sciencedirect.com/science/article/pii/S0026271413000747> (1^{er} juin 2013).
29. HE, Y.-J., SHEN, J.-N., SHEN, J.-F. & MA, Z.-F. State of health estimation of lithium-ion batteries : A multiscale Gaussian process regression modeling approach. *American Institute of Chemical Engineers Journal* **61**, 1589-1600. ISSN : 1547-5905. <http://onlinelibrary.wiley.com/doi/10.1002/aic.14760/abstract> (1^{er} mai 2015).

Conclusion générale et perspectives

Les contributions réalisées au cours des années de cette formation doctorale sont focalisées sur l'étude de certaines questions liées à l'élaboration d'approches hybrides de pronostic dans le domaine du PHM.

Tout d'abord, nous avons fourni une revue avancée des approches de pronostic disponibles, à savoir les approches basées sur la physique, les approches basées sur les données, les approches basées sur la connaissance et les modèles hybrides. En plus, nous avons présenté quelques prototypes de ces approches, y compris leur classification, leurs avantages et leurs limites. De point de vue application, nous avons présenté pour chaque méthode de pronostic les techniques populaires adoptées dans le domaine du PHM, en fournissant également des références de base adéquates. Des applications de domaine et des jeux de données largement utilisés sont spécifiés au lecteur intéressé pour développer des méthodes de pronostic fiables et surtout des tendances hybrides.

Deuxièmement, pour la construction et le développement des modèles, notre contribution dans cette thèse couvre l'élaboration de méthodes hybrides pour le pronostic industriel où de nombreux aspects sont considérés :

- Traitement des données d'entrée en proposant une phase de transformation des données d'apprentissage en valeurs de gradient dans laquelle les données générées sont susceptibles d'être analysées. Les procédures de transformation et de restauration sont clarifiées dans le deuxième chapitre de cette thèse ;
- Proposition et développement d'un ensemble de mécanismes d'agrégation et de sélection qui utilisent les sorties fournies par un ensemble de prédicteurs sélectionnés comme entrée pour fournir des résultats améliorés ;
- Introduction des opérateurs de moyenne pondérée ordonnée induite IOWA comme outil de fusion avec des spécifications à leur composantes clés l'ordre d'induction ;
- Proposition et développement d'une approche de sélection permettant de capturer la meilleure solution fournie par les prédicteurs en compétition à chaque instant t en se basant sur un critère proposé ;
- Proposition et implémentation des fonctions de pondération explicites (exponentielle, logarithmique et inverse) pour l'agrégation des sorties fournies par un ensemble de prédicteurs sélectionnés comme entrée pour la fusion ;
- Prise en considération de l'incertitude par l'estimation d'un intervalle de confiance autour des données prédites à base des fonctions de pondération proposées ;
- Conception et développement d'une méthode métaheuristique hybride basée sur des opérateurs génétiques où un chromosome est développé afin d'intégrer un ensemble de prédicteur participant à la génération des résultats améliorés.

Enfin, plusieurs simulations incluant de nombreux scénarios et configurations ont été réalisées dans les trois derniers chapitres. On a utilisé des jeux de données réelles fournis par le centre de jeu de données de la NASA traitant du mécanisme de dégradation des batteries lithium-ion. Les résultats obtenus reflètent la robustesse et l'efficacité des approches hybrides de pronostic implémentées, comme le confirme la comparaison avec certains articles traitant le même problème.

L'aspect important des méthodes de fusion proposées concerne la possibilité de leur exploitation par les utilisateurs intéressés dans une diversité d'approches de pronostic. Cela peut se faire en remplaçant simplement les prédicteurs adoptés dans ce travail (GPR et ANFIS) par d'autres outils alternatifs de pronostic.

Sur la base des approches de pronostic hybrides proposées et des principales contributions de ce travail, nous pouvons cibler certains perspectives et travaux futurs :

A court terme

- Inclusion d'une plus grande spécification du vecteur de pondération du IOWA en tenant compte des mesures définies par Yager (Orness et dispersion);
- Intégration de la recherche locale dans les méthodes de pronostic génétique hybride développées;
- Spécification du nombre d'éléments d'agrégation dans les fonctions de pondération proposés (exponentiel, logarithmique et inverse) en utilisant des stratégies plus élaborées au lieu de la procédure de sélection d'un pourcentage d'éléments.

A moyen terme

- Étude d'autres méthodes de transformation des données d'apprentissage telles que : La transformation en puissance, la transformation logarithmique et la transformation racine carrée *arcsin*;
- Adoption d'autres techniques d'optimisation, telles que les méthodes métaheuristiques, au lieu de la procédure de descente de gradient incluse dans les opérateurs IOWA;
- Utilisation d'autres prédicteurs comme entrée des outils de fusion et des schémas de pondération proposés au lieu des régresseurs GPR et ANFIS.

A long terme

- Développement d'autres méthodes de fusion de pronostic via l'étude de différentes classes d'opérateurs IOWA;
- Développement de nouvelles méthodes de fusion de pronostic et mise à niveau des approches développées en exploitant les technologie "Cloud computing" et "Internet of things".
- Développement d'autres méthodes de fusion de pronostic à base des algorithmes d'apprentissage profond.

Résumé

Récemment, les approches hybrides de pronostic ont été introduites comme une nouvelle alternative pour apporter des avantages supplémentaires et contourner les défauts des techniques conventionnelles. Le développement de nouvelles méthodologies hybrides constitue l'objectif principal de notre thèse. Pour ce faire, nous avons effectué une revue approfondie des approches de pronostiques existantes et en particulier les stratégies hybrides. En outre, un ensemble de mécanismes d'agrégation et de schémas de pondération, qui utilisent les sorties fournies par un ensemble de prédicteurs sélectionnés comme entrée pour fournir des résultats améliorés est proposé. Les outils de fusion et les procédures de pondération proposés sont élaborés sur la base d'opérateurs de moyenne pondérée ordonnée induite (IOWA), de fonctions de pondération analytiques explicites (exponentielle, logarithmique et inverse) et d'une méthode métaheuristique comprenant des opérateurs génétiques. Une multitude de simulations numériques ont été menées pour valider les performances des cadres de pronostic hybrides mis en œuvre, où les résultats obtenus se révèlent très compétitifs par rapport à des études similaires.

Mots clés : Approche hybride de pronostic, fusion, opérateurs IOWA, fonction de pondération analytique et algorithme génétique.

Abstract

Recently, hybrid prognostic approaches have been introduced as a new alternative to bring additional benefits and circumvent the shortcomings of conventional techniques. The development of new hybrid methodologies constitutes the principal objective of our dissertation. To this end, we have conducted a deep review about the existing prognostics approaches and particularly hybrid strategies. In addition, a set of aggregation mechanisms and weighting schemes, which uses the outputs delivered by a set of selected predictors as an input to provide ameliorated results, is proposed. The proposed fusion tools and weighting procedures are elaborated based on Induced Ordered Weighted Averaging Operators (IOWA), explicit analytical weighting functions (Exponential, logarithmic and inverse) and a metaheuristic method including genetic operators. Extensive numerical simulations have been conducted to validate the performance of the implemented hybrid prognostics frameworks, where the obtained findings are shown to be very competitive with respect to similar studies.

Keywords : Hybrid prognostics approach, fusion, IOWA operators, analytical weighting function and genetic algorithms

خلاصة

في الآونة الأخيرة ، تم تقديم مناهج التنبؤ للأعطال بالطرق الهجينة كبديل جديد لجلب فوائد إضافية والتغلب على أوجه القصور في التقنيات التقليدية. يشكل تطوير منهجيات هجينة جديدة للتنبؤ بالأعطال الهدف الرئيس لأطروحتنا. تحقيقاً لهذه الغاية ، أجرينا مراجعة عميقة حول مناهج التكهّنات الحالية والاستراتيجيات الهجينة بشكل خاص. بالإضافة إلى ذلك، فقد اقترحنا مجموعة من آليات التجميع وخطط الترجيح، والتي تستخدم المخرجات الناتجة عن مجموعة من المتنبئات المختارة كمدخل لتقديم نتائج محسنة. أدوات الدمج وإجراءات الترجيح المقترحة تم تطويرها بناءً على عوامل المتوسط المرجح المرتب المستحث، دوال ترجيح تحليلية صريحة (الأسية واللوغاريتمية والعكسية) وطريقة ما فوق اجتهدية تحوي مؤثرات وراثية. تم إجراء عمليات محاكاة عددية واسعة النطاق للتحقق من صحة أداء أطر التكهّنات الهجينة المنجزة، حيث تبين أن النتائج التي تم الحصول عليها تنافسية للغاية مقارنة بدراسات مماثلة.

الكلمات المفتاحية: الطريقة الهجينة للتنبؤ بالأعطال، التجميع، المتوسط المرجح المرتب المستحث، دالة ترجيح تحليلية وخوارزمية وراثية.