

# Approche statistique pour le pronostic de défaillance : Application à l'industrie du semi-conducteur

## THÈSE

présentée et soutenue publiquement le 04/03/2016

pour l'obtention du

**Doctorat de l'Université d'Aix-Marseille**

Spécialité Automatique

par

Thi-Bich-Lien NGUYEN

### Composition du jury

<i>Rapporteurs :</i>	M. Christophe BERENGUER	Professeur, Université Grenoble Alpes
	M. Antoine GRALL	Professeur, Université de Technologie de Troyes
<i>Examineurs :</i>	Mme G. DAUPHIN-TANGUY	Professeur, Ecole Centrale de Lille
	M. Vincent COCQUEMPOT	Professeur, Université Lille 1
	M. Mohand DJEZIRI	Maître de Conférences, Université d'Aix-Marseille (Co-encadrant de thèse)
	Mme Bouchra ANANOU	Maître de Conférences, Université d'Aix-Marseille (Co-encadrant de thèse)
	M. Mustapha OULADSINE	Professeur, Université d'Aix-Marseille (Directeur de thèse)
<i>Invité :</i>	M. Jacques PINATON	Ingénieur, STMicroelectronics Rousset



Mis en page avec la classe thloria.

# Remerciements

Je tiens tout d'abord à remercier à M. Mustapha Ouladsine, mon directeur de thèse pour ses remarques pertinentes, et pour le temps qu'il a su me consacrer malgré les grandes responsabilités qu'il prenne. Je remercie également Madame Bouchra Ananou, mon co-directeur de thèse pour sa gentillesse et ses conseils.

J'exprime ma reconnaissance à M. Mohand Djeziri, mon co-directeur de thèse pour avoir co-encadré cette thèse, pour les conseils et les encouragements, pour m'avoir toujours accordé sa confiance et le temps indispensable pendant ces trois ans.

Mes remerciements vont également à M. Jacques Pinaton, M. Laurent Bucelle - ingénieurs de STMicroelectronics pour leurs aides dans l'acquisition et l'interprétation des données des équipements. Je remercie également Quentin Lafuste, Mathieu Scotto et Julien Marino pour leurs aides dans l'alignement de données. Un grand merci à Baligh Mnassri et Radouane Ouladsine pour les discussions scientifiques intéressantes pendant mon premier temps de cette thèse.

Madame Geneviève Dauphin-Tanguy et Messieurs Antoine Grall, Christophe Berenger et Vincent Cocquempot m'ont fait l'honneur de participer au Jury de soutenance, je les en remercie profondément.

Je passe ensuite une dédicace spéciale à tous les jeunes gens que j'ai eu le plaisir de côtoyer durant ces quelques années à Marseille, à savoir Thu-Thuy Dang, Tuan-Luyen Chu, Mehdi Rahim, Marco Pocci, Idris Igoulalene, Aznam Yacoub, Mariam Melhem, Mohamed Ali Jebri, Remiel Feno, Jean-Jacques Honorine, etc.

Je remercie de plus tous les auteurs des programmes du domaine public que j'ai utilisés intensément durant cette thèse, à savoir tous les contributeurs à TEX, LATEX et Matlab. Un grand merci aux auteurs qui ont créé et amélioré le Template que j'ai profité pour la rédaction de cette thèse.

Pour leurs encouragements et leur soutien qui m'ont permis de faire cette thèse dans de bonnes conditions, je remercie chaudement mon ami Sébastien Ducros, ma famille, mes amis ainsi que le LSIS, qui a financé cette thèse. Je remercie également François-Xavier Filias pour ses conseils et son soutien significatifs sur mon projet professionnel.

Je tiens aussi à mentionner le plaisir que j'ai eu à rencontrer des personnes remarquables pendant les séminaires, les conférences et les voyages de cette thèse, je les remercie ici tous pour les échanges intéressants, les suggestions et les conseils.

*A ma famille,  
mes frères et mes soeurs*

## Résumé

Ce travail de thèse concerne le développement d'une méthode de pronostic de défaillance des systèmes de production en série. Une méthode de génération d'un indice de santé brut à partir d'un tenseur de données, appelée Méthode des Points Significatifs a été développée puis validée sur un exemple d'illustration. L'indice généré est ensuite traité par une nouvelle méthode appelée méthode des percentiles, qui permet de générer des profils monotones à partir d'un indice de santé brut. Les profils générés sont ensuite modélisés par un processus Gamma, et la fonction de densité de probabilité agrégée introduite dans ce travail a permis d'estimer le temps de vie résiduel (Remaining Useful Life (RUL)) dans un intervalle de confiance qui assure une marge de sécurité à l'utilisateur industriel. La méthode proposée est appliquée avec succès sur des données expérimentales issues des équipements de production industrielle.

**Mots clefs** : pronostic de défaillance, indice de santé, modélisation statistique, processus stochastiques, analyse multi-variée.

# Abstract

This thesis develops a fault prognosis approach for Discrete Manufacturing Processes. A method of raw health index extraction from a data tensor, called *Significant Points* was developed and validated on an illustrative example. The generated index is later processed by a new method, called *Percentile Method*, which allows to generate the monotonic profiles from the raw health index. These profiles are then modelled by a Gamma process, and the aggregate probability density function introduced in this work allowed to estimate the Remaining Useful Life (RUL) in a confidence interval that ensures a safety margin for industrial users. The proposed method is applied successfully on the experimental data of industrial production machines.

**Keywords** : fault prognostics, health index, statistical modelling, stochastic process, multivariate analysis.

# Table des matières

Table des figures

ix

## Introduction générale

### Chapitre 1

#### État de l'art

1.1	Introduction . . . . .	8
1.2	Définitions du pronostic . . . . .	9
1.3	Classification des approches du pronostic . . . . .	11
1.3.1	Approches basées sur les modèles physiques . . . . .	11
1.3.2	Approches basées sur la connaissance d'experts . . . . .	13
1.3.3	Approches guidée par des données . . . . .	14
1.3.4	Approches hybrides . . . . .	21
1.4	Evaluation de la performance du pronostic . . . . .	22
1.5	Conclusion . . . . .	24

### Chapitre 2

#### Extraction de l'indice de santé brut

2.1	Introduction . . . . .	28
2.2	Position du problème . . . . .	28
2.3	Approches proposées . . . . .	29
2.3.1	Méthode 1 : Reconstruction de la Dégradation par ACP (RD-ACP) . . . . .	30
2.3.2	Méthode 2 : Reconstruction de la Dégradation par ACP Multi-voies (RD-ACPM) . . . . .	31
2.3.3	Méthode 3 : Points significatifs combinés avec l'ACP (PS-ACP) . . . . .	36
2.3.4	Validation du choix de la première composante principale . . . . .	39
2.4	Comparaison et discussion . . . . .	44

2.5	Exemple d'illustration . . . . .	47
2.5.1	Application de la méthode RD-ACP . . . . .	49
2.5.2	Application de la méthode RD-ACPM . . . . .	49
2.5.3	Application de la méthode PS-ACP . . . . .	51
2.5.4	Analyse du résultat . . . . .	52
2.6	Conclusion . . . . .	53

<b>Chapitre 3</b>
-------------------

<b>Pronostic de défaillance</b>
---------------------------------

3.1	Pré-traitement . . . . .	57
3.1.1	Méthodes existantes . . . . .	57
3.1.2	Proposition : Méthode des percentiles . . . . .	60
3.1.3	Exemple d'illustration . . . . .	64
3.2	Estimation du RUL des systèmes à un mode de fonctionnement (Méthode Gamma-percentiles) . . . . .	72
3.2.1	Modélisation . . . . .	72
3.2.2	L'estimation de temps de vie résiduel (RUL) . . . . .	72
3.2.3	Exemple d'illustration . . . . .	74
3.3	Estimation du RUL des systèmes à multi-modes de fonctionnement (Modèle IS à multi-modes) . . . . .	80
3.3.1	Modélisation de l'indice de santé . . . . .	80
3.3.2	Estimation du RUL . . . . .	83
3.3.3	Exemple d'illustration . . . . .	85
3.4	Conclusion . . . . .	89

<b>Chapitre 4</b>
-------------------

<b>Application industrielle</b>
---------------------------------

4.1	Introduction . . . . .	92
4.2	Application 1 : Description de l'équipement . . . . .	93
4.3	Génération de l'indice de santé . . . . .	94
4.3.1	Méthode RD-ACP . . . . .	94
4.3.2	Méthode RD-ACPM . . . . .	97
4.3.3	Méthode PS-ACP . . . . .	98
4.3.4	Analyse des résultats . . . . .	99
4.4	Pronostic de défaillance . . . . .	101

---

4.4.1	Pré-traitement de l'indice de santé brut . . . . .	101
4.4.2	Modélisation de l'indice de santé et Estimation du RUL . . . . .	103
4.5	Application 2 . . . . .	109
4.6	Conclusion . . . . .	114
4.6.1	Applications considérées . . . . .	114
4.6.2	Perspective d'implémentation dans le milieu industriel . . . . .	115

<b>Conclusion générale</b>
----------------------------

---

<b>Annexe A Abréviations</b>	<b>121</b>
<b>Références bibliographiques</b>	<b>123</b>

---



# Table des figures

1	Les opérations basiques dans le semi-conducteur [1]	2
2	Ligne de production	3
3	Les données collectées sur un équipement	3
1.1	Les différentes formes de maintenance normalisées selon FD X60-000	8
1.2	Hiérarchie des familles d'approche pour le pronostic d'un point de vue méthodologique	11
1.3	Réseau de neurones pour le pronostic [40]	15
1.4	Classification des méthodes d'analyse de la tendance	16
1.5	Horizon pronostique $\alpha$	22
1.6	Exemple illustrant la Performance $\alpha - \lambda$	23
1.7	Exemple illustrant l'Exactitude Relative	24
1.8	Exemple illustrant la Convergence : l'ordre décroissance de la vitesse et la qualité d'apprentissage : cas 1, 3, 2	24
1.9	Approche de pronostic proposée	25
2.1	Tenseur de données	29
2.2	Trois étapes des méthodes de génération de l'IS	30
2.3	Deux restructuration pour la méthode RD-ACP	30
2.4	Overture du tenseur dans la dimension des produits	32
2.5	Overture du tenseur dans la dimension des variables	32
2.6	Procédure d'identification des points significatifs	36
2.7	Les variables identifiées dans la matrice réduite	42
2.8	Les variables centrées et réduites à une variance unitaire	43
2.9	Résultat de l'ACP pour la matrice réduite	44
2.10	Profils de la dégradation et de la perturbation	47
2.11	Amplitude relative de la dégradation portée par les capteurs et observations	47
2.12	Amplitude relative de la perturbation portée par les capteurs et observations	48
2.13	Les séquences d'observation des 5 derniers produits comparées à celles des 5 premiers produits	48
2.14	Identification de la direction de la dégradation	49
2.15	L'IS porté par : (a) les capteurs ; (b) les observations	49
2.16	Contribution de chaque capteur sur la valeur de l'EPQ	50
2.17	Reconstruction de la dégradation de la méthode RD-ACPM	50
2.18	L'IS généré par la méthode RD-ACPM	51

2.19	Les points significatifs identifiés par la méthode PS-ACP . . . . .	51
2.20	L'IS généré par la méthode PS-ACP . . . . .	52
2.21	La grandeur de la corrélation entre les IS générés par les méthodes proposées et la dégradation réelle . . . . .	52
3.1	Une forme commune de l'IS normalisé . . . . .	61
3.2	IS prend la même valeur à plusieurs instants . . . . .	62
3.3	Exemple du calcul des percentiles : (a) - Les percentiles correspondants pour les valeurs de $T_y$ ; (b) - Les valeurs de temps correspondants pour les $\{66, 67, \dots, 74\}$ -ième percentiles . . . . .	63
3.4	51 profils $Z^p$ extraits à partir de $X_t$ . . . . .	64
3.5	Les composantes de l'indice de santé brut . . . . .	65
3.6	Deux profils de l'IS : (a) Unimodale; (b) Multimodale . . . . .	65
3.7	Résultat de l'application des outils statistiques sur les IS : (a) Pour l'IS UM, (b) Pour l'IS MM . . . . .	66
3.8	Résultat de l'application de la DME sur les IS : (a) Pour l'IS UM, (b) Pour l'IS MM . . . . .	67
3.9	Le filtre passe-bas appliqué sur les deux indices de santé : (a) Pour l'IS UM, (b) Pour l'IS MM . . . . .	67
3.10	L'application de la décomposition en ondelettes sur les deux indices de santé : (a) Pour l'IS UM, (b) Pour l'IS MM . . . . .	68
3.11	L'application de la méthode des percentiles sur l'IS UM . . . . .	69
3.12	L'application de la méthode des percentiles sur l'IS MM . . . . .	69
3.13	Illustration de la moyenne des fdp individuelles . . . . .	74
3.14	L'indice de santé et les seuils . . . . .	75
3.15	Le paramètre $\hat{\mu}_t$ estimé . . . . .	75
3.16	Le RUL estimé par le processus de Wiener conventionnel . . . . .	76
3.17	Le RUL estimé par le processus Gamma avec le profil extrait par la DME . . . . .	77
3.18	Le RUL estimé par le processus Gamma avec le profil extrait par la DO . . . . .	77
3.19	Illustration de la fdp du temps de défaillance pour chaque percentile . . . . .	78
3.20	Illustration de la fdp agrégée du temps de défaillance . . . . .	78
3.21	La méthode Gamma-percentiles : Le RUL estimé comparé au RUL réel . . . . .	79
3.22	Diagramme de la modélisation de la dégradation et l'estimation du RUL . . . . .	81
3.23	Deux covariables qui représentent cinq modes de condition opérationnelle . . . . .	85
3.24	Les indices de santé correspondants . . . . .	86
3.25	La comparaison du RUL estimé et du RUL réel pour le scénario S.I . . . . .	87
3.26	La comparaison du RUL estimé et du RUL réel pour le scénario S.II . . . . .	87
4.1	Evolution de la dégradation . . . . .	93
4.2	Détection de la dégradation . . . . .	94
4.3	L'identification des variables significatives basée sur la reconstruction de la dégradation . . . . .	95
4.4	Les indices de santé extraits par la méthode RD-ACP . . . . .	96
4.5	(a) Détection de la dégradation de la plaque de test par l'EPQ, (b) Contribution des capteurs portés sur l'EPQ de la plaque à l'observation $k = 351$ . . . . .	96

---

4.6	Identification des capteurs significatifs par la reconstruction de dégradation	97
4.7	L'indice de santé extrait par la méthode RD-ACPM	97
4.8	Les trois premières composantes principales des points en mouvement	98
4.9	Les points significatifs avec $p = 50$ percentiles	98
4.10	L'indice de santé extrait par la méthode PS-ACP	99
4.11	Les mesures des données de test comparées aux données d'apprentissage sur les capteurs	100
4.12	L'indice de santé normalisé	101
4.13	Les profils extraits par les techniques DME, DO et la méthode des percentiles sur un ensemble complet de données (Scénario S.I).	102
4.14	Les profils extraits par les techniques DME, DO et la méthode des percentiles sur une partie des données (Scénario II)	102
4.15	Les indices de santé d'apprentissage et de test	104
4.16	L'évolution du paramètre de dérive $\mu_t$ en appliquant le processus Wiener mis-à-jour sur les deux profils $Z^{DME}$ et $Z^{DO}$	104
4.17	Le RUL estimé par le processus de Wiener conventionnel	105
4.18	Le RUL estimé par la méthode Gamma-percentiles	105
4.19	Résultat de la métrique Horizon du Pronostic	106
4.20	Résultat de la métrique Performance $\alpha - \lambda$	107
4.21	Résultat de la métrique Exactitude Relative	107
4.22	Le RUL estimé et son IC à 90% comparés au RUL réel	108
4.23	Résultat de la métrique Horizon du Pronostic	108
4.24	Résultat de la métrique Performance $\alpha - \lambda$	109
4.25	Résultat de la métrique Exactitude Relative	109
4.26	Les points significatifs avec $p = 50$ percentiles	110
4.27	Les points significatifs avec $p = 80$ percentiles	111
4.28	Les trois premières composantes principales des points significatifs	111
4.29	Les profils extraits par la méthode des percentiles sur l'indice de santé	111
4.30	Le RUL estimé et son IC à 90% comparés au RUL réel	112
4.31	Résultat de la métrique Horizon du Pronostic	112
4.32	Résultat de la métrique Performance $\alpha - \lambda$	113
4.33	Résultat de la métrique Exactitude Relative	113
4.34	Exemple d'un incident de logiciel affectant l'indice de santé généré	115
4.35	Exemple de l'indice de santé avec une pause de machine	116



# Introduction générale

## Contexte et problématique

Ce travail de recherche est réalisé au Laboratoire des Sciences de l'Information et des Systèmes (LSIS-UMR-CNRS 7296), dont les activités de recherche sont organisées en équipes projets autour de trois pôles, le pôle Informatique, le pôle Systèmes et le pôle Image. Ce travail de thèse s'inscrit dans les activités du pôle Système, il est réalisé dans l'équipe projet ESCODI (ESTimation, COMmande et DIagnostic) dans le cadre du projet industriel MAGE (Microcontrôleur pour l'Autonomie à Grande Efficacité énergétique).

Le projet MAGE, porté par ST-Microelectronics, vise entre-autres à réduire la variabilité des caractéristiques des transistors par le biais de démonstrateurs permettant la maîtrise du rendement de la ligne de production, ainsi que la surveillance du vieillissement des équipements. En effet, le rendement est lié à l'état des équipements et à la stratégie de maintenance mise en oeuvre. En général, quelle que soit la stratégie de maintenance adoptée, elle va nécessiter une période d'arrêt du système. La maîtrise du choix de cette période et de sa durée sont des facteurs qui impacts directement le rendement.

Dans le cas de la maintenance corrective, cette période et sa durée sont subies par l'industriel, et peuvent avoir des conséquences économiques importantes. Une stratégie de maintenance préventive systématique nécessite plus de périodes d'arrêt pour maintenance que nécessaire, ce qui engendre un manque de production, qui peut à long terme nuire à la compétitivité d'une entreprise. Les maintenances conditionnelles et prévisionnelles sont donc meilleures, mais elles nécessitent une connaissance et une analyse de l'état de dégradation du système, qui n'est ni disponible ni visible dans la majorité des cas, il doit être déduit des connaissances physiques, des connaissances d'experts et des mesures disponibles sur le système. Le pronostic de défaillance consiste à exploiter ces connaissances afin de générer des indices caractérisant l'état futur du système ainsi que son temps de vie résiduel (Remaining Useful Life (RUL)).

La problématique dans cette thèse est liée au processus de production du semi-conducteur, qui est complexe car la matière première doit subir les différentes opérations de production ainsi que les tests intermédiaires avant d'obtenir le produit fini. La Fig. 1 montre la phase de fabrication effective des puces avec six opérations basiques :

- L'oxydation/diffusion

- Le dépôt d'une couche diélectrique ou métallique
- La Photolithographie/Lithographie
- La Gravure
- Le Dopage
- Le Polissage mécano-chimique

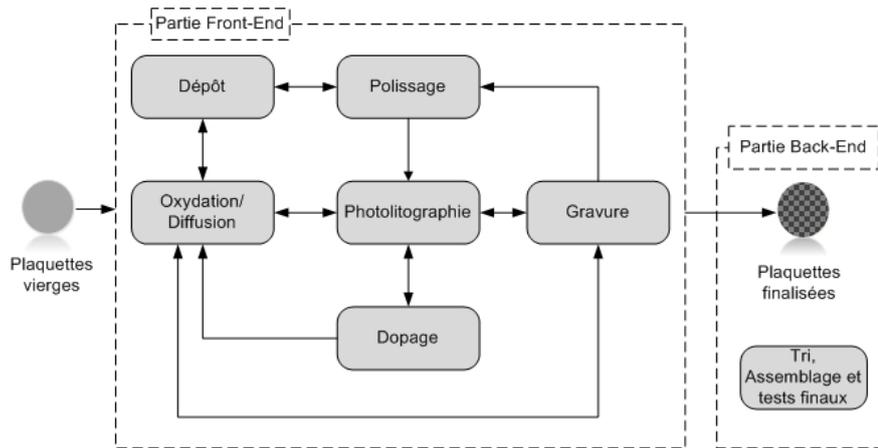


FIGURE 1 – Les opérations basiques dans le semi-conducteur [1]

Les opérations sont réalisées sur des équipements différents, comme illustré la Fig. 2. Dans ce cas, la qualité du produit fini dépend de l'état de santé des équipements utilisés pour sa fabrication. La surveillance du vieillissement de ces équipements devient donc indispensable. Pour le faire, les approches existantes dans la littérature tel que les méthodes basées sur le modèle physique sont difficile à mettre en oeuvre car ce sont des équipements complexes difficiles à modéliser. L'évolution rapide des technologies et des produits ne permet pas de formaliser à temps les connaissances d'expert pour le pronostic de défaillance. Ainsi, la complexité des équipements de production de semi-conducteurs et leur instrumentation ont orienté notre choix vers des approches guidées par les données. Les informations disponibles sont issues des mesures d'un ensemble de capteurs pendant un temps de process ; ainsi, les données disponibles sur chaque équipement peuvent être résumées en une matrice de trois dimensions, comme illustré dans la Fig. 3.

Comme ce travail de thèse s'inscrit dans le cadre d'un projet industriel, l'approche développée doit répondre à deux aspirations principales :

- Une aspiration industrielle : La méthode de pronostic doit tenir compte de l'information disponible et du caractère industriel des données. Les algorithmes doivent être mis en oeuvre sans imposer des modifications du processus de fabrication chez STMicroelectronics.
- Une aspiration de recherche : L'approche développée doit constituer une contribution théorique claire, et apporter des solutions aux verrous scientifiques liés au pronostic

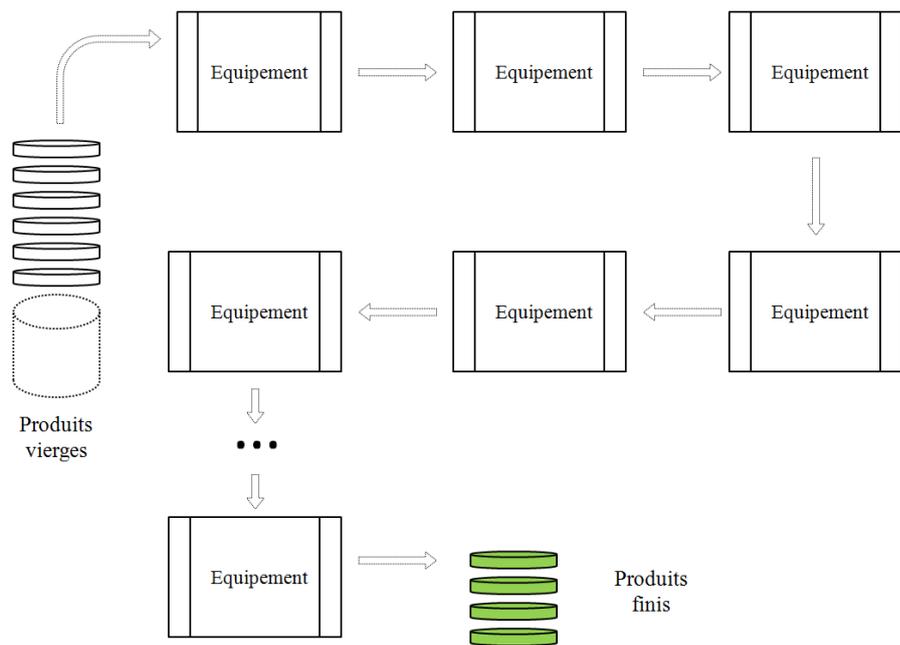


FIGURE 2 – Ligne de production

de défaillances à base de données.

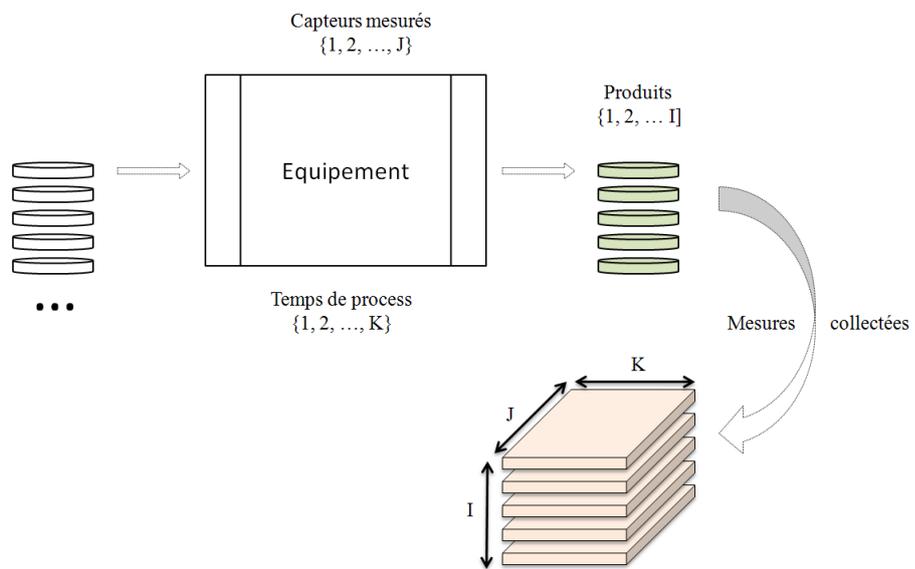


FIGURE 3 – Les données collectées sur un équipement

## Contributions apportées

La première contribution apportée dans ce travail de thèse concerne le développement d'un algorithme de pronostic de défaillance à partir d'un tenseur de données. Ce travail de recherche est construit autour de l'hypothèse d'une dégradation monotone et progressive. La méthode est organisée en trois modules : un module de réduction de la taille des données, un module de traitement de l'indice de santé brut et un module de pronostic. Dans chaque module, nous avons apporté des solutions innovantes à des verrous scientifiques bien identifiés. Le module de réduction est consacré à l'extraction des caractéristiques utiles à partir du tenseur de données brutes. Dans cette partie, et dans un souci de généralité, nous avons proposé trois méthodes applicables aux systèmes de production en série [154], [155], [156]. Parmi ces trois méthodes, la méthode des points significatifs est sans doute la plus originale, elle associe la technique classique d'analyse multi-variée ACP (Analyse en Composantes Principales) à un algorithme de recherche des points significatifs (points qui présentent une variabilité) ainsi qu'une méthode d'analyse de corrélation [156]. L'étape de réduction, comme son nom l'indique, permet de réduire la taille des données pour extraire un indice de santé qui peut être considéré comme une synthèse de plusieurs éléments ; un profil monotone (représentant l'évolution de la dégradation), des perturbations, le bruit et certaines valeurs aberrantes. L'association de ces éléments donne lieu à un profil commun d'indice de santé brut, constaté dans plusieurs applications [147], [148], [117], [118]. Le traitement de l'indice de santé brut est réalisé par une nouvelle méthode appelée méthode des percentiles [158], qui permet de générer plusieurs profils monotones décrivant au mieux le processus de dégradation, cette nouvelle technique de pré-traitement vient pallier à la perte d'information engendrée par les méthodes statistiques de pré-traitement. La méthode de percentile génère un ensemble de profils monotones, pour les exploiter au mieux dans l'estimation du RUL. Dans le module de pronostic, nous avons développé une méthode nommée Gamma-percentiles, qui consiste à modéliser les profils par un processus Gamma puis calculer la probabilité du RUL en utilisant une fonction de densité de probabilité agrégée [158]. Cette méthode a été validée sur des données industrielles réelles fournies par ST-Microelectronics.

La deuxième contribution concerne le développement d'une méthode de pronostic de défaillances des systèmes à fonctionnement multi-modes [157]. L'approche développée s'appuie sur l'hypothèse que la valeur future de l'IS est une fonction de l'état actuel du système, du temps, et des modes d'utilisation (consignes) supposés connus.

## Organisation du manuscrit

Le chapitre 1 est consacré à un état de l'art détaillé des méthodes de pronostic de défaillances existantes dans la littérature. Après la présentation des définitions du concept du pronostic, une classification des approches existantes est proposée, puis chaque approche est illustrée avec un exemple choisi dans la littérature, pour montrer ses avantages et ses limites. Ce chapitre se poursuit par la présentation de métriques d'évaluation de la

---

performance du pronostic, et se termine par une conclusion qui décrit la problématique traitée et introduit l'approche développée.

Le chapitre 2 présente les méthodes développées pour l'extraction d'indices de santé bruts à partir d'un tenseur de données. Les méthodes proposées sont formalisées, puis appliquées sur un exemple de simulation. Les résultats obtenus ont permis d'analyser les avantages et limites de chaque méthode.

Le chapitre 3 décrit les méthodes développées pour l'estimation du RUL. Ce chapitre commence par la présentation des outils de pré-traitement de données existants dans la littérature, qui sont ensuite appliqués à l'indice de santé brut obtenu au chapitre 2 afin de démontrer la nécessité du développement d'une nouvelle méthode de pré-traitement. La nouvelle méthode proposée, appelée méthode des percentiles est ensuite détaillée dans ce chapitre, puis appliquée à son tour à l'indice de santé brut. Le résultat obtenu est analysé puis comparé aux résultats obtenus par les autres méthodes. Après le pré-traitement, une nouvelle méthode de modélisation de la tendance de la dégradation, appelée méthode Gamma-percentiles, est développée et puis appliquée à un exemple d'illustration pour mettre en évidence ses performances.

Étant donné que beaucoup de systèmes industriels fonctionnent en multi-modes, nous avons développé dans ce chapitre une méthode de pronostic de défaillance adaptée au fonctionnement multi-modes, appelée modèle Indice de Santé à multi-modes. La méthode développée a été appliquée à un exemple numérique dans ce chapitre.

Le chapitre 4 illustre les applications de l'approche de pronostic développée sur des équipements industriels de fabrication de semi-conducteurs. Les résultats obtenus montrent l'efficacité de la méthode présentée dans ce travail de thèse, et ouvrent de nouvelles perspectives de perfectionnement de la méthode et de développement futur de nouvelles approches.



# 1

## État de l'art

### Sommaire

---

<b>1.1</b>	<b>Introduction</b>	<b>8</b>
<b>1.2</b>	<b>Définitions du pronostic</b>	<b>9</b>
<b>1.3</b>	<b>Classification des approches du pronostic</b>	<b>11</b>
1.3.1	Approches basées sur les modèles physiques	11
1.3.2	Approches basées sur la connaissance d'experts	13
1.3.3	Approches guidée par des données	14
1.3.3.1	Méthodes de l'Intelligence Artificielle	14
1.3.3.2	Méthodes d'analyse de la tendance	16
1.3.4	Approches hybrides	21
<b>1.4</b>	<b>Evaluation de la performance du pronostic</b>	<b>22</b>
<b>1.5</b>	<b>Conclusion</b>	<b>24</b>

---

## 1.1 Introduction

La maintenance des systèmes industriels se décline en plusieurs types en fonction du moment auquel elle intervient dans le cycle de vie d'un système. D'après la norme AF-NOR FD X60-000 en 2002 [2], les types de maintenances sont organisés comme le montre la Fig.1.1.

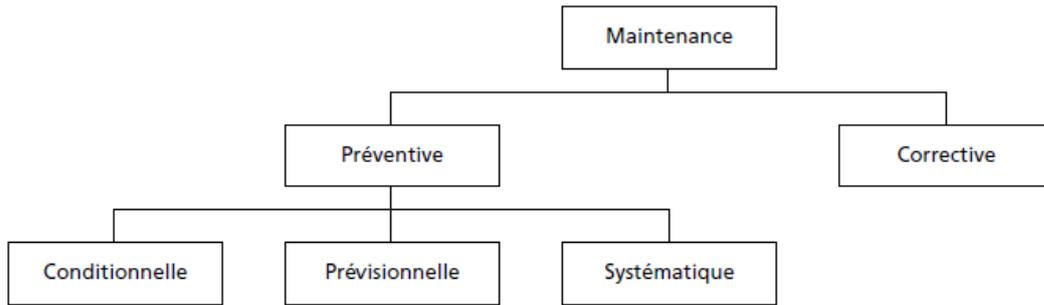


FIGURE 1.1 – Les différentes formes de maintenance normalisées selon FD X60-000

*Maintenance corrective* : "Maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise."

*Maintenance préventive* : "Maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits, elle est destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien". La maintenance préventive est subdivisée en :

- *Maintenance systématique* : "Maintenance préventive exécutée à des intervalles de temps préétablis ou selon un nombre défini d'unités d'usage mais sans contrôle préalable de l'état du bien".
- *Maintenance conditionnelle* : "Les remplacements ou les mises en état des pièces, les remplacements ou les appoints des fluides ont lieu après une analyse de leur état de dégradation. Une décision volontaire est alors prise d'effectuer les remplacements ou les mises en état nécessaires".
- *Maintenance prévisionnelle* : "Maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien, permettant de retarder et de planifier les interventions".

Pour une intervention suite d'une panne, le coût de maintenance ainsi que le coût de perte de production sont plus élevés qu'une intervention préalable. C'est pour cela que la maintenance préventive est préférable, surtout pour des biens coûteux et ceux qui sont indispensables dans la chaîne de production.

Dans la maintenance conditionnelle et prévisionnelle, les pré-requis sont une connaissance et une analyse de l'état de dégradation du système. Pourtant, dans la réalité, l'état

de dégradation n'est ni disponible ni visible dans la majorité des cas, il doit être déduit des connaissances physiques, des connaissances d'experts et des mesures disponibles du système. Le pronostic de défaillance consiste à exploiter ces connaissances afin de générer des indices caractérisant l'état futur du système ainsi que son temps de vie utile (Remaining Useful Life (RUL)). Les définitions du pronostic, la classification des approches du pronostic et les méthodes existantes d'extraction de l'indice de santé sont présentées et analysées dans ce chapitre.

## 1.2 Définitions du pronostic

La norme internationale *ISO 13381* de 2004 définit le pronostic comme l'estimation de la durée de vie utile et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance. Cependant, dans la littérature, les définitions associées au concept du pronostic s'adaptent au contexte, aux objectifs et au domaine d'application considéré, parmi ces interprétations on trouve :

- Wang et al. (1999) : *In the industrial and manufacturing areas, prognosis is interpreted to answer the question : what is the remaining useful lifetime of a machine or a component once an impending failure condition is detected and identified* [15] : Dans les domaines de l'industrie et de la fabrication, le pronostic est interprété pour répondre à la question : quelle est le temps de vie résiduel d'une machine ou d'un composant lorsque un début de défaillance est détecté et identifié.
- Mathur et al. (2001) : *Prognosis is an assessment of the future health* [16] : Le pronostic est une évaluation de l'état de santé futur.
- Lebold et al. (2001) : *Prognostic is the ability to perform a reliable and sufficiently accurate prediction of the remaining useful life of equipment in service. The primary function of the prognosticis to project the current health state of equipment into the future taking into account estimates of future usage profiles* [17] : Le pronostic est la capacité d'effectuer une prévision fiable et suffisamment exacte du temps de vie résiduel de l'équipement en fonctionnement. La fonction principale du pronostic est de projeter l'état de santé actuel de l'équipement dans l'avenir en tenant compte de l'estimation des profils d'utilisation futurs.
- Byington et al. (2002) : *Prognosticis the ability to predict the future condition of a machine based on the current diagnostic state of the machinery and its available operating and failure history data* [3] : Le pronostic est la capacité de prédire l'état futur d'une machine basée sur l'état actuel de diagnostic de la machine et les données d'historique de défaillance.
- Jardine et al. (2006) : *Prognostics deals with fault prediction before it occurs. Fault prediction is a task to determine whether a fault is impending and estimate how soon and how likely a fault will occur* [18] : Le pronostic s'occupe de la prédiction du défaut avant qu'il se produise. La prédiction des défauts permet de déterminer si une faute est imminente et estimer dans combien de temps et à quelle probabilité un défaut va se produire.
- Muller et al. : (2008) : *Prognostics is the ability to perform the future of an item from its present, its past, its degradation laws and the maintenance actions to be investigated*

[19] : Le pronostic est la capacité d'estimer l'état futur d'un élément à partir de son état présent, son état passé, ses lois de dégradation et les actions de maintenance à faire.

Dans les publications récentes, la notion de pronostic est de plus en plus clairement associée à l'estimation du RUL :

- Tobon et al. (2010) : *Fault prognostics can be defined as the prediction of when a failure might take place* [20] : Le pronostic de défaillance peut être défini comme la prédiction du moment où une défaillance pourra avoir lieu.
- Gucik-Derigny (2011) : *Le pronostic consiste à prédire l'évolution de l'état futur de santé d'un système et d'estimer le temps de vie restant d'un système avant qu'une ou plusieurs défaillances n'apparaissent sur ce dernier* [21].
- Singleton et al. (2014) : *Effective diagnostic and prognostic tools are essential for timely fault detection and remaining useful life (RUL) prediction* [84] : Les outils efficaces pour le diagnostic et pronostic sont essentiels pour la détection de défauts à temps et la prédiction du temps de vie résiduel (RUL).
- Sun et al. (2014) : *Prognostics usually focuses on the prediction of the failure time or the Remaining Useful Life (RUL) of a system or Component in service by analysis of data collected from sensors* [88] : Le pronostic se concentre généralement sur la prédiction du temps de défaillance ou du temps de vie résiduel d'un système ou d'un composant en service par l'analyse des données enregistrées par des capteurs.
- Lee et al. (2014) : *Prognostics can be interpreted as the process of health assessment and prediction, which includes detecting incipient failure and predicting RUL* [22] : Le pronostic peut être interprété comme l'évaluation et la prédiction de l'état de santé d'un système, qui inclut la détection d'un début de dégradation et la prédiction du RUL.
- Lim et al. (2015) : *Prognostic is the analysis of the symptoms to predict future condition and remaining useful life (RUL)* [85] : Le pronostic est l'analyse des symptômes pour la prédiction des conditions de fonctionnement futures et du RUL.

On constate que les références cités ci-dessus définissent le pronostic comme la prédiction de la probabilité du temps de vie résiduel (Remaining Useful Life (RUL)) basée sur une analyse des données de surveillance et de l'état actuel du système. Jardine et al. [18] ont formulé le RUL comme suit :

$$RUL_t = T - t | T > t, Z(t) \quad (1.1)$$

où  $T$  est la variable aléatoire représentant l'instant de la défaillance,  $t$  est le temps actuel et  $Z(t)$  représente les conditions de fonctionnement du système jusqu'à l'instant  $t$ . C'est donc la définition du pronostic que nous retenons dans ce travail de thèse.

#### Remarque :

Dans la suite du manuscrit, nous utilisons les expressions *exact* et *exactitude* comme suit : plus le RUL estimé est proche du RUL réel, plus le résultat du pronostic est *exact*, donc, l'*exactitude* augmente lorsque la valeur absolue de la différence entre le RUL estimé et le RUL réel tend vers 0.

## 1.3 Classification des approches du pronostic

D'après la Classification de Byington en 2002 [3], il existe trois approches de pronostic : basées sur des modèles physiques, basées sur des connaissances d'experts et guidées par des données, comme illustré dans la Fig. 1.2. Cette classification met en évidence l'étendue du champ d'application, le coût de mise en oeuvre, l'exactitude et la complexité de chaque approche.

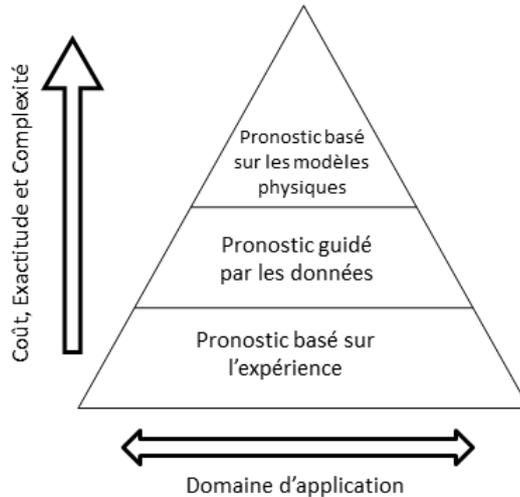


FIGURE 1.2 – Hiérarchie des familles d'approche pour le pronostic d'un point de vue méthodologique

Des méthodes hybrides qui combinent les propriétés des trois approches commencent à émerger dans la littérature [32], [33], [34], [35], dans le but d'exploiter toute l'information disponible et de répondre aux exigences des industriels.

### 1.3.1 Approches basées sur les modèles physiques

Elles estiment le RUL d'un système à partir d'une représentation du comportement physique de son processus de dégradation. Ces méthodes demandent une compréhension complète du comportement du système sur l'ensemble des niveaux, microscopique et macroscopique.

Les modèles comportementaux sont généralement décrits par des équations différentielles partielles [24], [25] ou des représentations d'état [26], [27]. Une fois le modèle physique disponible, le comportement du processus actuel est comparé à celui du modèle en fonctionnement normal pour détecter un début de dégradation. Après détection du début de dégradation, le modèle du système en fonctionnement dégradé est lancé pour simuler l'évolution de la dégradation dans le temps ainsi que son influence sur l'état du système. Le RUL correspond au temps que met la dégradation pour atteindre le seuil généralement

prédéfini de défaillance.

Un exemple de ces approches est décrit dans [26], il présente le pronostic basé sur un modèle physique sous forme d'équations différentielles. Le modèle du système en présence de la dégradation est décrit sous la forme :

$$\begin{aligned} \dot{x} &= f(x, \lambda(\theta), u) \\ \dot{\theta} &= \epsilon g(x, \theta) \\ y &= Cx + Du + v \end{aligned} \quad (1.2)$$

où  $x \in \mathbb{R}^n$  est l'ensemble de variables d'état associées au comportement dynamique rapide du système;  $\theta \in \mathbb{R}^m$  est l'ensemble de variables à dynamique lente liées à la dégradation du système;  $u \in \mathbb{R}^l$  est le vecteur d'entrées; le vecteur de paramètres  $\lambda \in \mathbb{R}^q$  est une fonction de  $\theta$ ; la constante de taux  $0 < \epsilon \ll 1$  définit la séparation d'échelle de temps entre la dynamique rapide et la dérive lente;  $y \in \mathbb{R}^p$  est le vecteur de sortie et  $v$  est le bruit de mesures.

Dans le cas de la surveillance des fissures, la variable  $\theta$  est reliée à la croissance de la fissure, et sa valeur est liée à la taille de la fissure par la loi Paris-Erdogan :

$$d\theta/dn = C(\Delta K)^\gamma \quad (1.3)$$

où  $\Delta K = Y(\theta)(\Delta s)\sqrt{\pi\theta}$  est le facteur d'intensité de la contrainte.  $Y(\theta)$  représente la géométrie de la fissure,  $\Delta s$  est la plage de la contrainte,  $C$  et  $\gamma$  sont les constantes du matériau. L'équation ci-dessus peut être réécrite :

$$d\theta/dn = \epsilon\phi_1(\theta)\phi_2(p) \quad (1.4)$$

où  $\epsilon = C$ ,  $\phi_1(\theta) = (Y(\theta)\sqrt{\pi\theta})^\gamma$ ,  $p = \Delta s$  et  $\phi_2(p) = p^\gamma$ . Pour faciliter la démarche de pronostic, une transformation linéaire est proposée dans l'équation 1.5 pour normaliser la dynamique lente  $\theta$  :

$$\xi_t = \frac{\theta_t - \theta_0}{\theta_M - \theta_0} \quad (1.5)$$

où  $\theta_M$  est la dégradation critique (défaillance supposée connue),  $\xi_t$  est la variable normalisée de la dégradation à l'instant  $t$  (à la défaillance  $\xi_t = 1$ ). La mesure de la dégradation  $\xi$  ( $0 \leq \xi \leq 1$ ) correspond à la variable  $\theta$ , ( $\theta_0 \leq \theta \leq \theta_M$ ). Ainsi :

$$\begin{aligned} \dot{x}_t &= f(x_t, \lambda(\xi_t), u_t) \\ \dot{\xi}_t &= \eta\phi_1(\xi_t)\phi_2(p_t) \\ y_t &= Cx_t + Du_t + v \end{aligned} \quad (1.6)$$

L'estimation du RUL est réalisée par une projection dans le temps de l'évolution des dynamiques lente et rapide. Connaissant la valeur de la dégradation à l'instant  $t$  et le temps de défaillance  $T$  correspondant à  $\xi_T = 1$ , le RUL à l'instant  $t$  est donné par l'équation suivante :

$$RUL_t = T - t \quad (1.7)$$

L'exemple ci-dessus montre qu'en plus des connaissances approfondies du comportement normal du système, ces méthodes requièrent une connaissance solide du mécanisme de dégradation du système. Par souci de simplification, le modèle des équations 1.2 tient compte de l'influence de la dégradation sur la dynamique rapide du système, mais pas l'inverse, alors que dans la réalité il y a une interaction qui n'est pas négligeable. L'identification paramétrique est aussi une limite considérable des méthodes à base de modèles physiques. Dans l'exemple précédent, les constantes du matériau, les facteurs d'intensité et les paramètres du modèle d'état ne sont pas évidents à identifier, en particulier lorsque les modèles sont non linéaires par rapport aux paramètres. Néanmoins, ces méthodes ne nécessitent pas une base de données sur le fonctionnement défaillant du système qui ne sont pas toujours disponibles.

Lorsque les modèles sont disponibles et précis, ces méthodes donnent une estimation exacte du RUL. En pratique, il existe des modèles des systèmes en fonctionnement normal, par contre les modèles physiques des processus de dégradation sont difficiles à formaliser. Cette contrainte a favorisé l'émergence de méthodes hybrides qui utilisent le modèle physique du système en fonctionnement normal pour générer un indice de santé (résidu) associé à des modèles mathématiques (autorégressifs, stochastiques) dépourvus de sens physique pour modéliser la tendance de la dégradation et estimer ainsi le RUL [30], [33], [31].

### 1.3.2 Approches basées sur la connaissance d'experts

Ces approches établissent la similarité entre des situations observées et une historique de données de défaillances afin de déduire le RUL. Les données comprennent généralement une base des connaissances accumulées par des experts et une base de règles pour l'application de ces connaissances aux problèmes particuliers. Les règles sont formulées comme des déclarations SI-ALORS (IF-THEN) qui sont normalement basées sur les faits heuristiques acquis par experts sur un certain nombre d'années. Pour être utile, la base de connaissance doit être complète, exacte et mise à jour.

La logique classique décrit une règle comme vraie ou fausse. Pourtant, il n'est pas toujours possible de définir des ensembles avec autant de précision. La théorie de la logique floue est donc utilisée afin de surmonter ce déficit et permettre de prendre une décision avec une variable de "degré de vérité" [37], [38], [39], [36], [41]. Ces méthodes sont régulièrement combinées avec les autres modèles de pronostic comme les réseaux de neurones [32] et les modèles auto-régressifs [38].

Un exemple représentatif de ces approches est donné dans [39], où un ensemble de règles typiques est déclaré comme :

$$\text{SI } x_1 \in \mathcal{Z}_1, x_2 \in \mathcal{Z}_2, \dots \text{ et } x_n \in \mathcal{Z}_n \text{ ALORS } y_r \in \Psi_r, (r = 1, 2, \dots, m) \quad (1.8)$$

où  $x_i$  est la  $i^{\text{me}}$  entrée,  $\mathcal{Z}_i$  est l'ensemble flou des valeurs de  $x_i$ . Le résultat  $y_r$  est un élément

dans l'ensemble flou de cible  $\Psi_r$ . Pour introduire une dynamique dans l'expression 1.8, une relation dynamique entre  $\{x_i\}$  et  $\{y_j\}$  est décrite en fonction du temps  $t$  :

$$Y^t = X^t \otimes R \quad (1.9)$$

où  $\otimes$  signifie un produit tensoriel,  $X^t = [x_1(t), \dots, x_n(t)]$  est un vecteur d'entrées défini par l'ensemble flou dynamique  $\mathcal{Z}(t)$ ,  $Y^t = [y_1(t), \dots, y_r(t)]$  est un vecteur de sorties défini par l'ensemble flou dynamique  $\Psi(t)$  et  $R = [\mu_{ij}]_{n \times m}$  est la matrice floue relative à déterminer.

Le pronostic ici consiste à prédire l'état virtuel du système  $Y^{t+\Delta t}$  en se basant sur les conditions de fonctionnement prévues  $X^{t+\Delta t}$ . Le RUL à l'instant  $t$  est estimé lorsque  $Y^{t+\Delta t}$  dépasse un seuil de défaillance, dans ce cas,  $\Delta_t$  est le RUL à l'instant  $t$ .

Cet exemple illustre la mise en oeuvre de ces méthodes, qui est plus simple comparée aux méthodes basées sur le modèle physique car elle ne requiert pas une compréhension complète du comportement physique et du processus de la dégradation. Mais leur implémentation requiert une base de connaissance d'expert assez complète pour construire les règles. Les méthodes expertes donnent des résultats moins exacts, car elles se basent sur la perception humaine. Dans le cas où l'estimation du RUL a besoin d'un niveau rigoureux d'exactitude, ces approches ne sont pas adaptées.

### 1.3.3 Approches guidée par des données

Elles estiment le RUL par l'analyse d'une grande masse de données observées. Grâce au perfectionnement des systèmes de capteurs modernes ainsi que les technologies de traitement du signal et de stockage de données, ces méthodes sont largement utilisées aujourd'hui pour le pronostic. Elles peuvent être divisées en deux catégories : les méthodes de l'Intelligence Artificielle (IA) et les méthodes d'analyse de tendance.

#### 1.3.3.1 Méthodes de l'Intelligence Artificielle

Elles estiment le RUL d'un système à partir d'une grande quantité de données en utilisant les outils de l'Intelligence Artificielle qui sont les réseaux de neurones artificiels et ses variantes [36], [40], [42], [43], [46]. Différents types de données peuvent être utilisés comme entrées de ces méthodes : des indices de surveillance, des caractéristiques du système ou un historique de la maintenance, etc.

La méthode présentée dans [40] est un exemple qui illustre l'utilisation des réseaux de neurones pour le pronostic. Dans ce travail, un réseau de neurones de type Feed-Forward, noté  $FN$ , est utilisé pour estimer le RUL avant l'usure totale des roulements comme illustré dans la Fig. 1.3.

$M$  roulements sont utilisés pour l'apprentissage. Pour chaque roulement  $m$ , un réseau de neurones  $FN_m$  est construit. Les données considérées sont des données vibratoires sur

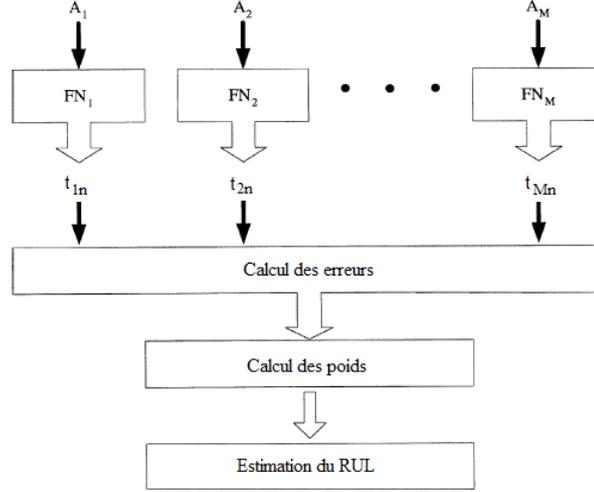


FIGURE 1.3 – Réseau de neurones pour le pronostic [40]

une période allant du fonctionnement normal jusqu'à la défaillance totale. Le spectre de fréquence est calculé sur toutes les données, puis la fréquence porteuse de la défaillance totale et ses six premières harmoniques sont extraits, pour chaque roulement  $m$  à l'échantillon  $n$ , le vecteur  $A_{mn} = [a_{mn}^1, \dots, a_{mn}^7]$  est obtenu. La sortie du réseau représente le temps de fonctionnement  $[t_{mn}]$ . Ces données sont ainsi utilisées pour l'apprentissage. L'évolution de l'amplitude moyenne des échantillons est supposée suivre une loi exponentielle  $\alpha e^{\beta t}$ .

Pour tenir compte du degré d'exactitude de chaque réseau, les sorties de réseau sont pondérées par des coefficients calculés comme suit :

$$e_{mn}^k = (t_{mn} - p_{kn})^2 \quad (1.10)$$

$$x_{mn}^k = \frac{\sum_{m=1}^M e_{mn}^k}{e_{mn}^k} \quad (1.11)$$

$$W_{mn} = \frac{x_{mn}^k}{\sum_{m=1}^M x_{mn}^k} \quad (1.12)$$

avec  $k, k \in \{1, \dots, K\}$  l'ensemble des roulements de test,  $p_{kn}$  est le temps de fonctionnement estimé du roulement  $k$  à l'échantillon  $n$ . Pour un nouveau roulement, le temps de fonctionnement  $t_n$  à l'échantillon  $n$  est donc donné par :

$$t_n = \sum_{m=1}^M W_{mn} t_{mn} \quad (1.13)$$

Avec un seuil de défaillance connu  $D$ , le temps de défaillance estimé peut être calculé à partir du réseau construit. A l'échantillon  $n$ , le RUL estimé est donc la différence entre le temps de défaillance estimé et le temps de fonctionnement réel.

Les avantages de ces méthodes sont : la compréhension physique du système n'est pas requise, possibilité d'utiliser plusieurs types de données pour les entrées, les logiciels de calcul sont disponibles et l'apprentissage est évolutif. L'exemple ci-dessus montre aussi que la mise en oeuvre des outils de l'IA requiert des données de qualité et en quantité importante, ce qui nécessite un pré-traitement des données brutes. Dans ce cas, une analyse fréquentielle a été faite sur les données brutes pour isoler l'information utile à l'apprentissage. Cependant, la grande limite de ces méthodes vient du manque de transparence sur la façon dont la sortie est obtenue à partir du réseau d'apprentissage, ce qui rend difficile l'interprétation physique des sorties.

### 1.3.3.2 Méthodes d'analyse de la tendance

Ces méthodes estiment le RUL d'un système en étudiant l'évolution de l'état du système, qui est représenté par un indicateur qualitatif déduit à partir des données de surveillance. Cet indicateur peut être appelé *indice de santé* et noté  $X(t)$  où  $t$  est le temps. Ces méthodes peuvent être classées en deux catégories : les modèles statistiques et les modèles stochastiques, comme illustré dans la Fig. 1.4.

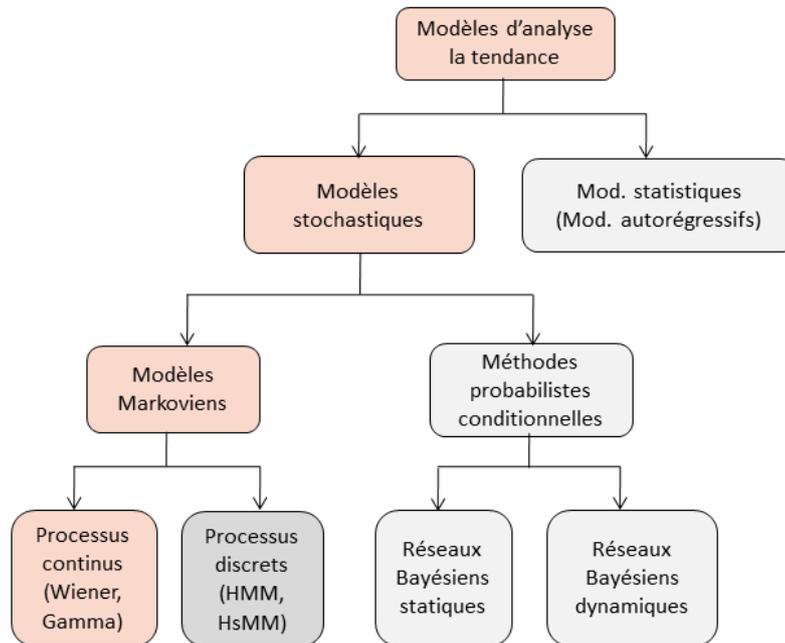


FIGURE 1.4 – Classification des méthodes d'analyse de la tendance

**A. Modèles statistiques** : Les modèles auto-régressifs ARMA (*AutoRegressive Moving Average*), ARIMA (*AutoRegressive Integrated Moving Average*) ou ARMAX (*AutoRegressive Moving Average eXogenous inputs*) initialement utilisés pour la prédiction de séries temporelles, sont utilisés pour l'estimation du RUL en considérant la valeur future de la dégradation comme une fonction linéaire des entrées du système, des observations

passées et des bruits aléatoires.

Pour illustrer l'utilisation de ces méthodes, prenons l'exemple du modèle ARMA. Une série temporelle  $\{x_t | t = 1, 2, \dots\}$  est générée par un modèle ARMA  $(p, q)$  comme suit :

$$x_t = \sum_{i=1}^p \phi_i x_{t-i} + \sum_{j=0}^q \theta_j \epsilon_{t-j}, \quad (\theta_0 = 1) \quad (1.14)$$

où  $x_t$  est une variable de la série à l'instant  $t$ ,  $p$  et  $q$  sont des nombres entiers non-nuls,  $p$  est l'ordre de la partie auto-régressive,  $q$  est l'ordre de la partie moyenne mobile,  $\{\epsilon_t\}$  indique la série du bruit.  $\{\phi_i, i = 1, \dots, p\}$  et  $\{\theta_j, j = 1, \dots, q\}$  sont des paramètres à estimer.

Pour utiliser ce modèle pour le pronostic, on considère que  $x_t$  est un indice de santé qui représente l'état du système et on suppose connu un seuil de défaillance  $D$ . Le RUL à l'instant  $t$  du système, noté  $h_t$ , est calculé comme suit :

$$h_t = \min\{\Delta t : x_{t+\Delta t} \geq D | x_t < D\} \quad (1.15)$$

Parmi les travaux qui appliquent ces modèles pour le pronostic, [47] qui utilise un modèle ARMA, [49] qui incorpore un modèle ARMA dans un logiciel de fusion de données et de pronostic, [48] qui propose une extension du modèle ARIMA en utilisant le modèle de prévision Bootstrap (*Bootstrap forecasting*).

Ces modèles sont simples à mettre en place. Cependant, ils supposent que l'état futur est une fonction linéaire des entrées du système, des observations passées et du bruit, ce qui n'est pas souvent le cas dans la réalité. De plus, leur résultats sont sensibles aux conditions initiales, induisant ainsi une accumulation d'erreurs systématiques dans la prédiction.

**B. Modèles stochastiques** : les modèles stochastiques les plus utilisés pour le pronostic sont les processus Markoviens et les réseaux Bayésiens.

### **B.1. Processus Markoviens** :

Les processus Markoviens sont des processus sans mémoire, où la probabilité de l'état futur  $X_n$  ne dépend que l'état actuel  $X_{n-1}$  comme le montre l'équation suivante :

$$\mathbb{P}(X_n = x_n | X_{n-1} = x_{n-1}, \dots, X_0 = x_0) = \mathbb{P}(X_n = x_n | X_{n-1} = x_{n-1}) \quad (1.16)$$

$x_1, \dots, x_n$  sont liées aux différents états du système. Ces processus peuvent être divisés en deux catégories : les processus Markoviens continus et les processus Markoviens discrets, présentés dans la suite.

**B.1.1. Processus Markoviens continus** : Les processus Markoviens les plus utilisés dans la littérature pour le pronostic sont les processus de Wiener et les processus

Gamma. L'hypothèse des incréments indépendants conduit ces processus aux propriétés markoviennes car :  $X(t + \Delta t) - X(t)$  est indépendant de  $X(t)$  et  $X(t + \Delta t) = X(t) + (X(t + \Delta t) - X(t))$ ; le processus  $\{X(t), t \geq 0\}$  est donc un processus Markovien [50].

○ **Les processus de Wiener** sont des processus de Markov continus  $[X_t, t > 0]$ , avec un paramètre de dérive  $\mu$  et un paramètre de variance  $\sigma^2$ ,  $\sigma > 0$ . Ils sont bien adaptés à la modélisation des processus de dégradation qui varient au fil du temps avec un bruit gaussien. Ces processus sont décrits par le modèle de l'équation 1.17 [53] :

$$X_t = x_0 + \mu t + \sigma B(t) \quad (1.17)$$

où  $B(t)$  est le mouvement brownien. Le RUL  $H_{t_i}$  à un instant  $t_i$  est défini comme le temps que met la variable  $X_t$ , avec  $t > t_i$ , pour atteindre un seuil de défaillance prédéfini  $w$ , tel que :

$$H_{t_i} = \inf\{\Delta_{t_i} : X_{t_i+\Delta_{t_i}} \geq w | X_{t_i} < w\} \quad (1.18)$$

Dans la littérature, le RUL est souvent donné avec un intervalle de confiance, obtenu par le calcul d'une fonction de densité de probabilité donnée par l'expression 1.19 [54] :

$$f_{H_{t_i}}(h_{t_i}) = \frac{w - X_{t_i}}{\sqrt{2\pi t_{t_i}^3 \sigma^2}} \exp\left(-\frac{(w - X_{t_i} - \mu t_{t_i})^2}{2t_{t_i} \sigma^2}\right) \quad (1.19)$$

Un grand nombre des travaux applique ce processus et ses variantes [55], [56], [57], [58], [59]. Particulièrement, [60] qui propose un processus de Wiener avec un paramètre de dérive mis à jour  $\mu_t$ . La présentation de ce processus est comme suit :

$$X_t = x_{t_i} + \mu_{t_i}(t - t_i) + \varepsilon_{t_i,t} \quad (1.20)$$

$$\mu_{t_i} = \mu_{t_{i-1}} + \delta v \quad (1.21)$$

où  $\varepsilon_{t_i,t}$  est un bruit normalement distribué :  $\varepsilon_{t_i,t} \sim N(0, t - t_i)$ , l'erreur  $\delta v \sim N(0, Q)$ . Supposant que la valeur initiale  $\mu_0$  suit une distribution normale  $N(\hat{\mu}_0, P_0)$ .  $\mu_{t_i}$  est ensuite mis à jour en utilisant un filtre de Kalman :

$$\hat{\mu}_{t_i} = \mu_{t_{i-1}} + P_{t_i|t_{i-1}} F_{t_i}^{-1} (x_{t_i} - x_{t_{i-1}} - \mu_{t_{i-1}}(t_i - t_{i-1})) \quad (1.22)$$

où

$$P_{t_i|t_{i-1}} = P_{t_{i-1}} + Q \quad (1.23)$$

$$F_{t_i} = (t_i - t_{i-1})^2 P_{t_i|t_{i-1}} + \sigma^2(t_i - t_{i-1}) \quad (1.24)$$

La matrice de variance mise à jour de  $\mu_{t_i}$  est :

$$P_{t_i} = P_{t_i|t_{i-1}} - P_{t_i|t_{i-1}}(t_i - t_{i-1})^2 F_{t_i}^{-1} P_{t_i|t_{i-1}} \quad (1.25)$$

Pour une observation à l'instant  $t_i$  avec  $x_{t_i}$  donné, la tendance future du modèle de la dégradation est présentée comme suit :

$$X_t = x_{t_i} + \mu_{t_i}(t - t_i) + \sigma \varepsilon_{t_i,t} \quad (1.26)$$

L'estimation des paramètres  $(\hat{\mu}_0, P_0, Q, \sigma)$  peut être faite avec l'algorithme de maximisation de l'espérance [60].

La fonction de densité de probabilité (*fdp*) de l'estimation du RUL et le RUL moyen à l'instant  $t_i$  sont donc :

$$f_{t_i}(h_{t_i}) = \frac{w - X_{t_i}}{\sqrt{2\pi h_{t_i}^3 \sigma^2}} \exp\left(-\frac{(w - X_{t_i} - \mu_{t_i} h_{t_i})^2}{2h_{t_i} \sigma^2}\right) \quad (1.27)$$

$$RUL_{t_i} = \int_{h_{t_i}=0}^{\infty} h_{t_i} f_{t_i}(h_{t_i}) d(h_{t_i}) \quad (1.28)$$

$$(1.29)$$

○ **Le processus Gamma** est le plus approprié à la modélisation des détériorations monotones et graduelles [50]. En 1975, Abdel-Hameed [61] a proposé de l'utiliser comme un modèle de détérioration s'introduisant aléatoirement dans le temps ([62], [65], [63], [64]).

Mathématiquement, une quantité aléatoire  $X$  suit une distribution Gamma avec le paramètre de forme  $v > 0$  et le paramètre d'échelle  $u > 0$  si sa fonction de densité de probabilité (*fdp*) est donnée comme suit :

$$Ga(x|v, u) = \frac{u^v}{\Gamma(v)} x^{v-1} \exp(-ux) I_{(0,\infty)}(x) \quad (1.30)$$

où  $I_{(0,\infty)}(x) = 1$  pour  $x \in (0, \infty)$  et  $I_{(0,\infty)}(x) = 0$  pour  $x \notin (0, \infty)$ ,  $\Gamma(v) = \int_{z=0}^{\infty} z^{v-1} e^{-z} dz$  est la fonction Gamma pour  $v > 0$ .

Étant donné une fonction non-décroissante  $v(t)$ , continue à droite et à valeur réelle pour  $t \geq 0$ , avec  $v(t) \equiv 0$ , le processus Gamma avec la fonction de forme  $v(t) > 0$  et le paramètre d'échelle  $u > 0$  est un processus stochastique continu avec les caractéristiques suivantes :

1.  $X(0) = 0$  avec une probabilité de 1
2.  $X(\tau) - X(t) \sim Ga(v(\tau) - v(t), u)$  pour tout  $\tau > t \geq 0$
3.  $X(t)$  a des incréments indépendants

Notons  $X(t)$  la détérioration à l'instant  $t, t \geq 0$ , la fonction de densité de probabilité de  $X(t)$  est :

$$f_{X(t)}(x) = Ga(x|v(t), u) \quad (1.31)$$

Son espérance et sa variance sont :

$$E(X(t)) = \frac{v(t)}{u}, \quad VAR(X(t)) = \frac{v(t)}{u^2} \quad (1.32)$$

Un système est dit défaillant lorsque sa dégradation atteint un seuil prédéfini  $S$ . A partir de l'équation 1.31, la distribution du temps de défaillance à l'instant  $t$  est écrit comme

suit :

$$\begin{aligned} F(t) &= Pr\{T_S \leq t\} = Pr\{X(t) \geq S\} \\ &= \int_{x=S}^{\infty} f_{X(t)}(x)dx = \frac{\Gamma(v(t), Su)}{\Gamma(v(t))} \end{aligned} \quad (1.33)$$

où  $\Gamma(a, x) = \int_{z=x}^{\infty} z^{a-1}e^{-z}dz$  est la fonction Gamma incomplète avec  $x \geq 0$  et  $a > 0$ . La fdp du temps de défaillance à l'instant  $t$  est donc :

$$f(t) = \frac{\partial}{\partial t} \left[ \frac{\Gamma(v(t), Su)}{\Gamma(v(t))} \right] \quad (1.34)$$

Le temps de défaillance moyen et le RUL moyen sont donnés dans les équations suivantes :

$$\mathcal{T}_t = \int_{t=0}^{+\infty} t f(t) dt \quad (1.35)$$

$$RUL_t = \mathcal{T}_t - t \quad (1.36)$$

Les deux processus Markoviens présentés ci-dessus sont largement utilisés pour modéliser la dégradation, ils couvrent la majorité des profils de dégradation : linéaire et non-linéaire, bruité et monotone. Cependant, ces processus requièrent la disponibilité d'un indice de santé  $X(t)$  qui estime le niveau actuel de dégradation du système. Dans le cas où il n'y a que les données brutes de mesures, une étape de génération de l'indice de santé est nécessaire.

### **B.1.2. Processus Markoviens discrets :**

Ces modèles supposent qu'un système ou un composant, à tout instant, se trouve dans un état parmi un nombre limité d'états. En définissant la probabilité associée à chaque état et la probabilité associée à la transition d'un état à un autre, la probabilité d'une défaillance future peut être estimée. L'état futur ne dépend que de l'état précédent.

Les modèles les plus utilisés pour le pronostic de défaillance sont les modèle Markovien caché ([79] , [80]), et les modèles Markoviens semi-cachés ([81], [82]). Ils sont caractérisés par deux paramètres et trois distributions : (i) nombre d'états du système, (ii) nombre d'observations par état, (iii) une distribution de probabilité des transitions entre les états, (iv) une distribution de probabilité d'observations et (v) une distribution de probabilité initiale des états.

Ces méthodes permettent de modéliser plusieurs conditions de fonctionnement du système et scénarios de défaillance, mais requièrent un grand volume de données et de connaissances pour l'apprentissage. De plus, l'intensité du calcul qui est proportionnel au nombre des états peut devenir importante pour des systèmes à plusieurs états de fonctionnement.

**B.2. Modèles probabilistes conditionnelles** : ces modèles se basent sur le théorème de Bayes, qui décrit la probabilité conditionnelle et marginale de deux événements

stochastiques  $A$  et  $B$  comme suit :

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (1.37)$$

Ces méthodes décrivent l'état actuel sous la forme d'une fonction de probabilité conditionnelle, puis appliquent le théorème Bayes pour mettre à jour l'évaluation de probabilité du comportement futur. L'outil de modélisation le plus utilisé est le réseau bayésien qui est un modèle graphique probabiliste représentant des variables aléatoires sous la forme d'un graphe orienté acyclique. Dans le domaine de l'aéronautique, [78] utilisent le réseau avec les variables comme le poids de l'avion, la vitesse de l'atterrissage et le fonctionnement des freins pour prédire la défaillance des freins. Dans d'autres travaux de recherche, les réseaux bayésiens sont associés au filtre de Kalman ([83], [84], [85]) ou au filtre à particules ([86], [87], [88]) pour le pronostic de défaillances.

Ces modèles permettent d'utiliser des données bruitées et d'intégrer les connaissances d'expert. Cependant, leur résultats sont sensibles au choix de la distribution a priori.

### 1.3.4 Approches hybrides

Les approches présentées ci-dessus ont leurs avantages et leurs limites, et il n'est pas toujours possible de dissocier les deux. Ainsi, des chercheurs ont orienté leurs travaux vers le développement de méthodes hybrides (Fig. 1.4) dans le but d'exploiter les avantages des outils existants, et de compenser leurs limites, mais aussi pour réduire la complexité des calculs et faciliter l'implémentation dans le milieu industriel [90].

Par exemple : [91] présente une méthode de prédiction de la corrosion basée sur les lois physiques comme la loi de Faraday pour la croissance de la corrosion et la loi de Paris pour la fatigue. [92] construit un arbre de défaillance à partir des connaissances physiques des composants du système qui est ensuite utilisé pour isoler le composant qui se dégrade. Ensuite, le flux de données issus des capteurs est exploité par des méthodes guidées par des données afin d'extraire des caractéristiques de la dégradation et estimer le RUL. Il existe également plusieurs méthodes de pronostic qui combinent les réseaux de neurones et les techniques basées sur les connaissances d'experts [94], [95], [96].

Dans la littérature, le mot Hybride est aussi utilisé pour signifier une combinaison de techniques différentes pour le pronostic de défaillance, sans se soucier de la nature de l'approche, par exemple : [97] combine la régression logistique, le modèle auto-régressif et moyenne mobile, qui sont des méthodes à base de données, pour le pronostic de défaillance des outils de forage ; [98] combine le modèle de Markov caché et le modèle de prédiction gris (qui prend en charge les données incomplètes ou incertaines) pour la prédiction de défaillance.

Les méthodes hybrides peuvent constituer une bonne alternative dans un certain nombre d'applications sous réserve d'une bonne conception de la combinaison des ou-

tils.

## 1.4 Evaluation de la performance du pronostic

L'évaluation de la performance est devenue un élément capital dans le développement de la recherche dans le domaine du pronostic de défaillance, car plusieurs méthodes sont proposées ces dernières décennies, et chacune utilise des critères d'évaluation différents dans une variété des secteurs comme la médecine, le nucléaire, l'automobile et l'aéronautique. Les travaux dans [128], [129], [130], [131] vont dans le sens d'une normalisation de ces critères, et proposent des métriques de la performance applicable à un grand nombre de méthodes de pronostic. Ces métriques aident à établir les exigences de conception qui doivent être remplies, elles permettent de quantifier les limites de performance acceptables, pour comparer ainsi des méthodes différentes numériquement.

[131] a présenté une synthèse structurée des métriques d'évaluation de la performance du pronostic qui s'adaptent aux différents domaines d'application. Les métriques présentées dans un ordre croissant de performance sont l'Horizon du Pronostic (HP), la Performance  $\alpha - \lambda$ , l'Exactitude Relative (ER) et la Convergence. Les méthodes du pronostic peuvent être comparées à partir des scores calculés par ces métriques.

### Horizon du Pronostic

L'Horizon de Pronostic (HP) se définit comme la différence entre l'instant de la fin de vie (FV), soustrait à l'instant de prédiction auquel l'exactitude du RUL estimé est inférieure à un seuil donné. Ce seuil est défini par un paramètre  $\alpha$ . Plus HP est grand plus la performance est meilleure. Dans l'exemple de la Fig. 1.5, la méthode qui a donné HP1 comme résultat est plus performante que celle qui a donné HP2 puisque  $HP1 > HP2$ .

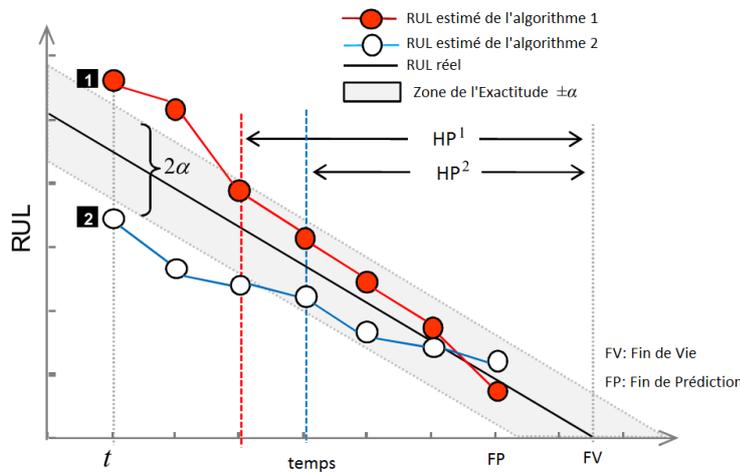


FIGURE 1.5 – Horizon pronostic  $\alpha$

## Performance $\alpha - \lambda$

La Performance  $\alpha - \lambda$  permet de quantifier la qualité de prédiction en vérifiant que la prédiction reste dans les limites indiquées aux instants spécifiques. Ces instants peuvent être définis comme un pourcentage de la période entre le début de la prédiction et l'instant de la défaillance, noté par  $\lambda \in (0, 1)$ .  $\alpha$  dans ce cas est un pourcentage du RUL réel. L'implémentation de cette métrique permet de répondre à la question suivante : est-ce que l'exactitude de la prédiction reste dans  $\alpha\%$  du RUL réel à l'instant spécifique  $\lambda$ ? Cette métrique est illustrée dans la Fig. 1.6.

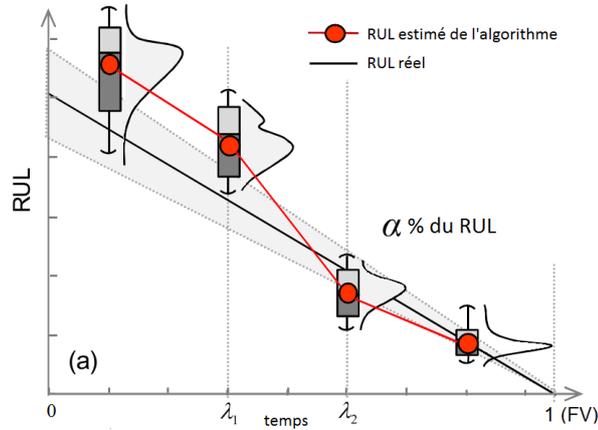


FIGURE 1.6 – Exemple illustrant la Performance  $\alpha - \lambda$

## Exactitude Relative (ER)

L'exactitude relative est un calcul quantitatif de l'exactitude :

$$ER_{\lambda} = 1 - \frac{|r^*(t_{\lambda}) - r(t_{\lambda})|}{r^*(t_{\lambda})} \quad (1.38)$$

où  $r^*(t_{\lambda})$  est le RUL réel à un instant donné  $t_{\lambda}$ ,  $r(t_{\lambda})$  est le RUL estimé à l'instant  $t_{\lambda}$ . L'exemple de la Fig. 1.7 montre qu'à l'instant  $t_{\lambda}$  avec  $\lambda = a$ , le RUL de l'algorithme 1 est plus exact que celui de l'algorithme 2, tandis qu'à l'instant  $t_{\lambda}$  avec  $\lambda = b$ , l'algorithme 2 donne un RUL plus exact.

## Convergence

La convergence est une métrique plus avancée, elle est utilisée pour estimer la vitesse et la qualité d'apprentissage d'un algorithme de pronostic lorsque de nouvelles données sont disponibles. Dans [131], il est démontré que la distance entre l'origine et le centre de gravité de l'aire sous la courbe du RUL quantifie la convergence. Cela signifie que plus la

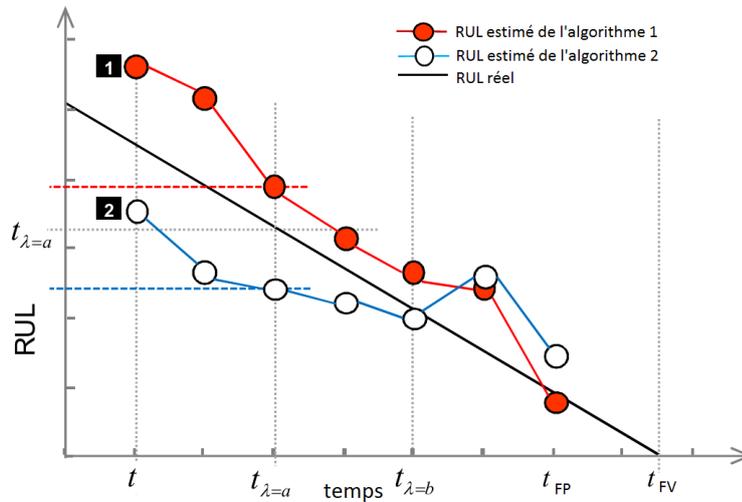


FIGURE 1.7 – Exemple illustrant l'Exactitude Relative

distance est petite, plus la convergence est rapide comme le montre l'exemple de la figure 1.8.

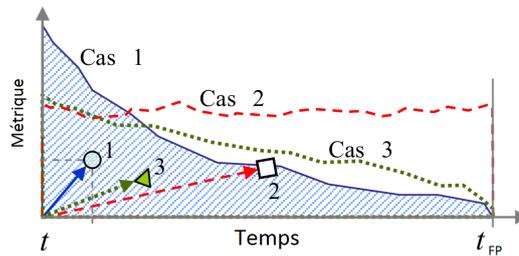


FIGURE 1.8 – Exemple illustrant la Convergence : l'ordre décroissance de la vitesse et la qualité d'apprentissage : cas 1, 3, 2

Ces métriques ne sont pas seulement utilisées pour la comparaison des algorithmes de pronostic mais aussi pour vérifier si un algorithme de pronostic répond aux performances souhaitées. Le choix de  $\alpha$  et  $\lambda$  peut requérir l'avis d'expert.

## 1.5 Conclusion

Dans le cadre de ce travail, les systèmes à surveiller sont en majorité des systèmes mécaniques complexes, dédiés à l'industrie du semi-conducteur. Les connaissances d'expert ainsi que les modèles physiques sont donc considérés indisponibles. Parmi des méthodes guidées par les données, les méthodes d'IA ne sont pas non plus convenables à cause de la complexité des systèmes.

Les outils statistiques, comme les modèles auto-régressifs ne sont pas bien adaptés dans ce contexte car ils se basent sur l'hypothèse de la linéarité entre la sortie future et les observations passées et présentes.

Les résultats des méthodes probabilistes conditionnelles sont sensibles au choix des probabilités a priori et leur calcul est complexe ; tandis que les processus Markoviens discrets nécessitent une estimation des probabilités initiales des états, de la probabilité de la transition entre les états. L'implémentation de ces méthodes n'est pas évidente dans notre cas d'étude, compte tenu la complexité des équipements étudiés, leur instrumentation et l'information disponible qui est une matrice de données en trois dimensions contenant la dégradation.

Les processus Wiener et Gamma dans l'ensemble des processus Markoviens continus sont bien adaptés au pronostic de défaillance des équipements industriels de la production en série à partir d'un tenseur de données car :

- Ils sont capables de modéliser un processus de dégradation bruité ou monotone
- Ils prennent en compte l'état de fonctionnement présent du système
- Ils ne demandent pas forcément des connaissances expertes ou physiques du système
- Ils fournissent une distribution du RUL, donc un intervalle de confiance
- Ils sont relativement faciles à mettre en oeuvre dans le milieu industriel, comparé aux autres approches citées ci-dessus.

Cependant, l'utilisation de ces modèles pour le pronostic de défaillances nécessite la levée de certains verrous scientifiques, que nous abordons dans ce travail de thèse en proposant une nouvelle approche organisée en deux modules comme illustré dans la Fig. 1.9.

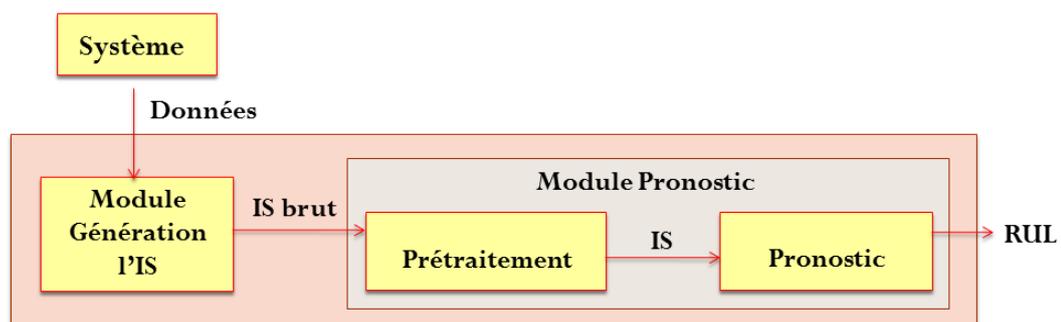


FIGURE 1.9 – Approche de pronostic proposée

Les entrées de l'algorithme de pronostic de défaillance sont les mesures brutes des capteurs installés sur le système. Le premier module, détaillé dans le chapitre 2, concerne la génération d'un indice de santé qui agrège l'état présent de dégradation du système à partir d'un ensemble important de données. Le deuxième module, abordé dans le chapitre 3, apporte une contribution dans le traitement de l'indice de santé (IS) brut de sorte à

extraire l'information utile (dégradation) du bruit, incertitudes et diverses perturbations externes; et présente une méthode de pronostic, basée sur l'indice de santé traité pour l'estimation du RUL dans un intervalle de confiance qui assure une marge de sécurité pour l'industriel. Une autre méthode de pronostic qui tient compte des changements des conditions de fonctionnement du système est également développée. Le chapitre 4 présente les résultats de l'application de nos méthodes sur les données fournies par STMicroelectronics.

# 2

## Extraction de l'indice de santé brut

### Sommaire

---

<b>2.1</b>	<b>Introduction</b>	<b>28</b>
<b>2.2</b>	<b>Position du problème</b>	<b>28</b>
<b>2.3</b>	<b>Approches proposées</b>	<b>29</b>
2.3.1	Méthode 1 : Reconstruction de la Dégradation par ACP (RD-ACP)	30
2.3.1.1	Étape 1 : Restructuration des données	30
2.3.1.2	Étape 2 : Réduction des données	31
2.3.1.3	Étape 3 : Génération de l'IS	31
2.3.2	Méthode 2 : Reconstruction de la Dégradation par ACP Multi-voies (RD-ACPM)	31
2.3.2.1	Étape 1 : Restructuration des données	31
2.3.2.2	Étape 2 : Réduction des données	31
2.3.2.3	Étape 3 : Génération de l'IS	35
2.3.3	Méthode 3 : Points significatifs combinés avec l'ACP (PS-ACP)	36
2.3.3.1	Étape 1 : Restructuration des données	36
2.3.3.2	Étape 2 : Réduction des données	36
2.3.3.3	Étape 3 : Génération de l'IS	38
2.3.4	Validation du choix de la première composante principale	39
<b>2.4</b>	<b>Comparaison et discussion</b>	<b>44</b>
<b>2.5</b>	<b>Exemple d'illustration</b>	<b>47</b>
2.5.1	Application de la méthode RD-ACP	49
2.5.2	Application de la méthode RD-ACPM	49
2.5.3	Application de la méthode PS-ACP	51
2.5.4	Analyse du résultat	52
<b>2.6</b>	<b>Conclusion</b>	<b>53</b>

---

## 2.1 Introduction

Les données issues des machines dans les systèmes industriels sont complexes et de grande dimension, nous avons donc naturellement opté pour le développement d'une méthode de pronostic de défaillance, qui commence par la réduction de la taille des données afin d'extraire uniquement les caractéristiques significatives pour le pronostic. Ces caractéristiques sont ensuite agrégées en un seul indice, appelé Indice de Santé (IS), qui décrit l'état de dégradation du système.

Il existe dans la littérature plusieurs techniques de réduction de la dimension de données. On distingue deux familles de techniques : les techniques linéaires et les techniques non-linéaires. Les techniques linéaires sont : Analyse en Composantes Principales [99] (ACP), Régression des Moindres Carrés Partiels [101], Analyse en Composantes Indépendantes [102]. Les techniques non-linéaires sont : ACP Noyaux [100], Fonction de Cartographie Isométrique [103], etc. Parmi ces méthodes, la plus utilisée pour la réduction de la dimension d'une matrice de données est l'ACP qui construit une représentation réduite des données avec une variance maximale. Une comparaison entre l'ACP et les autres techniques pour cet objectif est donnée dans [104].

Les méthodes basées sur l'ACP pour la génération d'indices de santé utilisent l'erreur de prédiction quadratique - EPQ (*en anglais : Squared Prediction Error*), l'indice Hotelling's T-carré et l'indice combiné EPQ et  $T^2$  [108], [115], [109]. Cependant, les indices de santé générés sont généralement utilisés pour le diagnostic et pas pour le pronostic, les caractéristiques recherchées sont donc différentes. Pour le diagnostic, l'objectif est de distinguer le fonctionnement normal des anomalies (défaut brusques, dégradation progressive, etc.). Pour le pronostic, le but étant de surveiller la dégradation progressive du système, l'IS recherché doit décrire un profil progressif [111], [55], [113].

Dans le cadre de ce travail, les systèmes sont des équipements de production qui effectuent des tâches répétitives sur plusieurs produits pendant un intervalle de temps quasiment fixe. Les données enregistrées sont donc structurées en trois dimensions : deux dimensions pour les variables capteurs et observations, et une dimension pour les produits. À partir de ce tenseur de données, et dans un souci de généralité, trois méthodes sont développées pour extraire les caractéristiques utiles pour le pronostic. Les deux premières sont applicables à des systèmes discrets et la troisième est applicable à des systèmes discrets et continus.

## 2.2 Position du problème

Soit un tenseur de données dont les axes représentent respectivement les variables : (capteurs) ( $J$ ), observations ( $K$ ) et produits ( $I$ ), comme illustrées dans la Fig. 2.1. Chaque point de ce tenseur est noté  $X_i^{j,k}$  où  $i \in 1, \dots, I$ ,  $j \in 1, \dots, J$  et  $k \in 1, \dots, K$  sont respectivement l'indice du  $i^{eme}$  produit,  $j^{eme}$  capteur et  $k^{eme}$  observation.

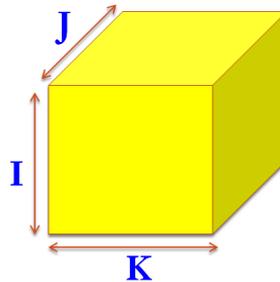


FIGURE 2.1 – Tenseur de données

Ayant ce tenseur comme information de départ, la question est : Comment extraire les caractéristiques de la dégradation à partir de cet ensemble complexe de données ? Pour le faire, les méthodes proposées dans ce chapitre s'appuient sur les hypothèses suivantes :

- *La dégradation se trouve dans les comportements temporels.*
- *La dégradation est progressive.*
- *Le bruit est de faible niveau, l'environnement est stable.*
- *Une base de données d'apprentissage est disponible : elle décrit l'état de fonctionnement du système, du fonctionnement normal jusqu'à un niveau de dégradation.* Les  $n$  premiers produits de la base de données décrivent donc un fonctionnement normal.
- *La dégradation et les perturbations sont indépendantes.*

Ces hypothèses sont appropriées dans le contexte de la production en séries, en particulier dans la fabrication du semi-conducteur.

## 2.3 Approches proposées

Dans un premier temps, l'ensemble de données doit être analysé et réduit. Cependant, une matrice de 3 dimensions (3D) est difficile à analyser directement, une étape préliminaire de transformation de la matrice 3D en une matrice de deux dimensions (2D) est donc nécessaire pour faciliter l'analyse et la réduction des données. L'identification des données significatives et la génération de l'IS se font en trois étapes comme illustré dans la Fig. 2.2. La pertinence des données significatives identifiées et de l'IS va dépendre de la façon dont la matrice 2D est structurées (Étape 1), la technique de réduction utilisée (Étape 2) et la méthode de génération de l'IS (Étape 3).

Les expressions suivantes sont utilisées dans la suite de cette section :

- *Point* : un point (capteur, observation) noté  $(j, k)$ .
- *Point significatif* : un point  $(j, k)$  qui porte la dégradation.
- *Capteur pertinent* : un capteur  $j$  qui porte la dégradation.
- *Observation pertinente* : une observation  $k$  qui porte la dégradation.

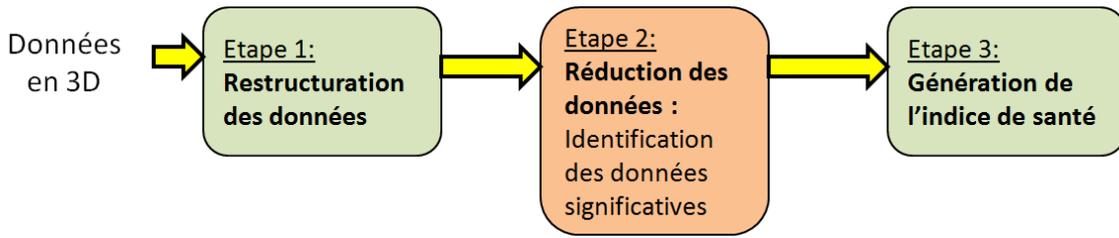


FIGURE 2.2 – Trois étapes des méthodes de génération de l'IS

## 2.3.1 Méthode 1 : Reconstruction de la Dégradation par ACP (RD-ACP)

### 2.3.1.1 Étape 1 : Restructuration des données

La matrice 3D ( $I \times J \times K$ ) devient une matrice 2D ( $I \times J$ ) (structure basée sur les capteurs) ou  $I \times K$  (structure basée sur les observations), la transformation du tenseur en matrice est décrite dans la Fig. 2.3.

- Structure basée sur les capteurs : le nombre de variables est  $J$  : les données de chaque produit  $i$  forment une matrice de taille  $J \times K$ , elle est réduite en un vecteur de taille  $J \times 1$   $[\bar{X}_i^1, \dots, \bar{X}_i^J]^T$  ; chaque élément  $\bar{X}_i^j$  est la valeur moyenne de la ligne  $j$  de la matrice  $J \times K$ . Cette structure permet d'identifier les capteurs pertinents. Le choix de la moyenne est justifié par la nature du phénomène de dégradation (Hypothèse 2.2) qui induit une dérive dans les mesures des capteurs, caractérisée par une dérive de la moyenne.
- Structure basée sur les observations : le nombre de variables est  $K$  : les données de chaque produit  $i$  forment une matrice de taille  $J \times K$ , elle est réduite en un vecteur de taille  $K \times 1$   $[\bar{X}_i^1, \dots, \bar{X}_i^K]^T$  ; chaque élément  $\bar{X}_i^k$  est la valeur moyenne de la colonne  $k$  de la matrice  $J \times K$ . Cette structure permet d'identifier les observations pertinentes.

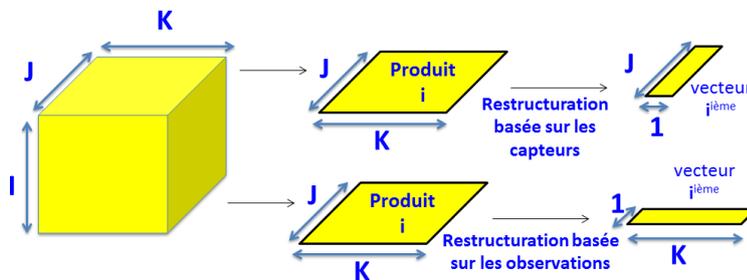


FIGURE 2.3 – Deux restructuration pour la méthode RD-ACP

### 2.3.1.2 Étape 2 : Réduction des données

Après restructuration, la matrice 2D peut être assimilée à une matrice de données d'un processus continu, donc, la détection et l'identification de la dégradation peuvent être basées sur les indices de détection les plus utilisés comme l'erreur de prédiction quadratique (EPQ), Hotelling T-Carré et l'indice combiné  $\varphi$  donnés dans [121], [108], [132].

L'ensemble des variables identifiées est noté  $\mathcal{V} = \{v_1, v_2, \dots, v_l\}$  où  $l$  est le nombre des éléments de  $\mathcal{V}$ . La matrice réduite, appelée  $\mathcal{X}_{\text{réduite}_1}$ , contient les données des variables significatives sur tous les produits, elle est définie dans l'équation 2.1 :

$$\mathcal{X}_{\text{réduite}_1} = \begin{pmatrix} \bar{X}_1^{v_1} & \bar{X}_1^{v_2} & \dots & \bar{X}_1^{v_l} \\ \bar{X}_2^{v_1} & \bar{X}_2^{v_2} & \dots & \bar{X}_2^{v_l} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{X}_I^{v_1} & \bar{X}_I^{v_2} & \dots & \bar{X}_I^{v_l} \end{pmatrix} \quad (2.1)$$

### 2.3.1.3 Étape 3 : Génération de l'IS

$\mathcal{X}_{\text{réduite}_1}$  est centrée et réduite (moyenne nulle et écart-type unité) pour appliquer l'ACP :

$$\mathcal{X}_{\text{réduite}_1} = T_r P_r^T \quad (2.2)$$

$T_r$  et  $P_r$  sont respectivement la matrice de composantes principales et la matrice des vecteurs propres de  $\mathcal{X}_{\text{réduite}_1}$ . La première composante est considérée comme l'indice de santé  $HI_1$ , il peut être calculé par l'équation suivante :

$$HI_1 = \mathcal{X}_{\text{réduite}_1} P_{r,1} \quad (2.3)$$

où  $P_{r,1}$  est le premier vecteur propre de  $P_r$ .

## 2.3.2 Méthode 2 : Reconstruction de la Dégradation par ACP Multi-voies (RD-ACPM)

### 2.3.2.1 Étape 1 : Restructuration des données

La matrice 3D ( $I \times J \times K$ ) devient une matrice 2D ( $(I \times K) \times J$ ) par un déploiement hybride comme suit : l'ensemble des données est déployé dans le sens du produit (Fig. 2.4), la matrice obtenue est centrée puis re-arrangée dans le sens des capteurs (Fig. 2.5), elle devient une matrice de taille  $(I \times K) \times J$ . D'après [122], cette restructuration permet d'enlever la variabilité des produits et de mettre en évidence la variabilité des capteurs.

### 2.3.2.2 Étape 2 : Réduction des données

La technique EWMA-H-MPCA (*Exponentially Weighted Moving Average - Hybrid - Multiway Principal Component Analysis*) [122], [123] est appliquée sur ces données pour

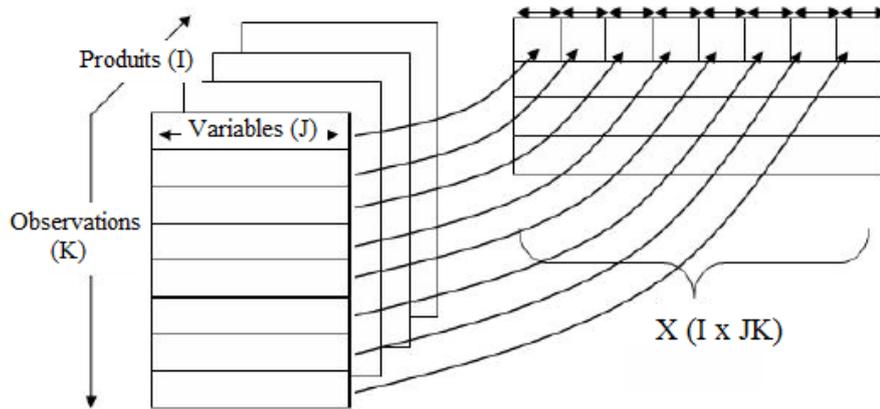


FIGURE 2.4 – Overture du tenseur dans la dimension des produits

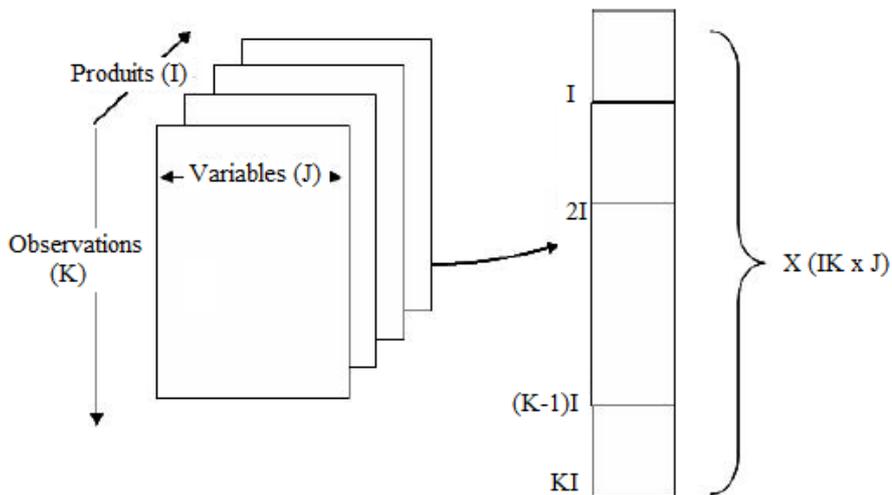


FIGURE 2.5 – Overture du tenseur dans la dimension des variables

prendre en compte la corrélation produit-à-produit, observation-à-observation et la dépendance dans l'ordre d'observation. L'identification des points significatifs et la reconstruction de la dégradation à partir de ces données [155] constituent une des contributions de ce travail de thèse et sont présentées ci-dessous.

### A. Détection de la dégradation

Après l'étape de restructuration des données, la matrice de données est donc de taille  $(I \times K) \times J$ . A partir de la matrice restructurée, une matrice notée  $X$ , et de taille  $(n \times K) \times J$  des données des  $n$  premiers produits qui représentent le fonctionnement normal du système.

La détection de la dégradation est résumée par les étapes suivantes :

- Application de l'ACP à la matrice  $X$  pour obtenir la matrice de projection  $\tilde{C}$  dans l'espace résiduel :

$$X = TP^T \quad (2.4)$$

$T$  et  $P$  sont respectivement la matrice des composantes principales et la matrice des vecteurs propres. Notons  $n_{cp}$  le nombre des composantes principales les plus significatives. Les  $n_{cp}$  premières colonnes de  $T$  et  $P$  sont notées respectivement  $\hat{T}$  et  $\hat{P}$ .  $\tilde{C}$  est la matrice de projection des données de la matrice  $X$  dans l'espace résiduel, calculée par l'équation 2.5 :

$$\tilde{C} = (\mathbb{I} - \hat{P}\hat{P}^T) \quad (2.5)$$

où  $\mathbb{I}$  est une matrice identité de taille  $J \times J$ .

- On note  $X_k$  de taille  $n \times J$  la matrice correspondant à chaque observation  $k$ , cette matrice est projetée dans l'espace résiduel, on obtient une nouvelle matrice  $e_k$ , de taille  $J \times n$  :

$$e_k = \tilde{C}X_k^T \quad (2.6)$$

- Afin de considérer la dynamique de la machine, EWMA est utilisée pour filtrer  $e_k$ , on obtient une nouvelle matrice  $e_{E,k}$  :

$$\begin{aligned} e_{E,k} &= \lambda e_k + (1 - \lambda)e_{E,k-1} = \lambda \sum_{j=1}^k (1 - \lambda)^{k-j} e_j \\ &= \lambda \sum_{j=1}^k (1 - \lambda)^{k-j} \tilde{C}X_j^T \\ &= \tilde{C} \times \left( \lambda \sum_{j=1}^k (1 - \lambda)^{k-j} X_j^T \right) = \tilde{C}X_{E,k}^T \end{aligned} \quad (2.7)$$

avec  $\lambda$  ( $0 \leq \lambda \leq 1$ ) le degré de la décroissance du poids des données précédentes dans le calcul et  $X_{E,k}^T = \lambda \sum_{j=1}^k (1 - \lambda)^{k-j} X_j^T$ .

- On note  $X_{nou}$  de taille  $K \times J$ , la matrice des données d'un nouveau produit différent des  $n$  premiers produits, et on note  $X_{nou,k}$  la ligne de  $X_{nou}$  correspondant à la  $k^{ieme}$  observation.  $X_{nou,k}$  est ensuite projetée dans l'espace résiduel puis filtrée par EWMA, la matrice obtenue est notée  $e_{nou,E,k}$ . Ensuite, l'Erreur de Prédiction Quadratique est appliquée à  $e_{nou,E,k}$  :

$$e_{nou,k} = \tilde{C}X_{nou,k}^T \quad (2.8)$$

$$\begin{aligned} e_{nou,E,k} &= \lambda e_{nou,k} + (1 - \lambda)e_{nou,E,k-1} \\ &= \lambda \sum_{j=1}^k (1 - \lambda)^{k-j} e_{nou,j} \\ &= \tilde{C} \times \left( \lambda \sum_{j=1}^k (1 - \lambda)^{k-j} X_{nou,j}^T \right) = \tilde{C}X_{nou,E,k}^T \\ &= \tilde{C}X_{nou,E,k}^T \end{aligned} \quad (2.9)$$

avec  $X_{nou,E,k} = \lambda \sum_{j=1}^k (1-\lambda)^{k-j} X_{nou,j}$ . L'Erreur de Prédiction Quadratique (EPQ) pour chaque observation  $k$  du nouveau produit est calculée comme suit :

$$EPQ_{nou,E,k} = e_{nou,E,k}^T e_{nou,E,k} \quad (2.10)$$

Le processus est considéré en fonctionnement normal tant que  $EPQ_{E,nou,k}$ ,  $k = 1 \rightarrow K$  est inférieur à une Limite de Contrôle (LC) donnée dans l'équation 2.11 :

$$LC_{E,k}^{EPQ} = \frac{v_{E,k}}{m_{E,k}} \chi_{2m_{E,k}/v_{E,k}}^2 \quad (2.11)$$

où  $m_{E,k}$  et  $v_{E,k}$  sont la moyenne et la variance de  $EPQ_{E,k}$  à l'observation  $k$  des données d'apprentissage (les  $n$  premiers produits).

### B. Reconstruction de la dégradation

La matrice  $X_{r,k}$  représente les valeurs de la matrice  $X_k$  après élimination de l'effet de la dégradation, elle est calculée comme suit :

$$X_{r,k} = X_k - \Xi_r \hat{F}_{r,k} \quad (2.12)$$

où  $\hat{F}_{r,k}$  est la dégradation estimée et  $\Xi_r$  est la matrice de direction de la dégradation. Après la décomposition en valeurs singulières de  $\tilde{C}^{\frac{1}{2}} \Xi_r$ , on obtient [132] :

$$\tilde{C}^{\frac{1}{2}} \Xi_r = \Xi_r^0 D_r V_r^T \quad (2.13)$$

Ainsi, la valeur reconstruite de  $e_k$ , notée  $e_{r,k}$  est calculée comme suit :

$$\begin{aligned} e_{r,k} &= \tilde{C} X_{r,k}^T \\ &= (I - \Xi_r^0 \Xi_r^{0T}) \tilde{C} X_k^T \end{aligned} \quad (2.14)$$

EWMA est ensuite utilisée pour filtrer  $e_{r,k}$ , on obtient :

$$\begin{aligned} e_{r,E,k} &= \lambda \sum_{j=1}^k (1-\lambda)^{k-j} e_{r,k} \\ &= \lambda \sum_{j=1}^k (1-\lambda)^{k-j} (I - \Xi_r^0 \Xi_r^{0T}) \tilde{C} X_j^T \\ &= (I - \Xi_r^0 \Xi_r^{0T}) \tilde{C} X_{E,k}^T \\ &= (I - \Xi_r^0 \Xi_r^{0T}) e_{E,k} \end{aligned} \quad (2.15)$$

De la même façon, pour la matrice  $X_{nou,k}$  de la  $k^{ieme}$  observation d'un nouveau produit, on calcule  $e_{r,nou,E,k}$  :

$$e_{r,nou,E,k} = (I - \Xi_r^0 \Xi_r^{0T}) \tilde{C} X_{nou,E,k}^T \quad (2.16)$$

L'EPQ reconstruite de la  $k^{ieme}$  observation du nouveau produit  $X_{nou}$  est calculée comme suit :

$$EPQ_{r,E,nou,k} = e_{r,nou,E,k}^T e_{r,nou,E,k} \quad (2.17)$$

La matrice de direction de dégradation  $\Xi_r$  est identifiée si l'EPQ après la reconstruction est inférieure de sa nouvelle limite de contrôle (LC) pour toutes les observations  $k \in \{1, \dots, K\}$ , qui est donnée comme suit :

$$LC_{EPQ_{r,E,k}} = \frac{v_{r,E,k}}{m_{r,E,k}} \chi_{2m_{r,E,k}^2/v_{r,E,k}}^2 \quad (2.18)$$

où  $m_{r,E,k}$  et  $v_{r,E,k}$  sont la moyenne et la variance de  $EPQ_{r,E,k}$  à l'observation  $k$  des données d'apprentissage. Une analyse de la contribution de l'EPQ peut permettre de choisir des capteurs potentiels, comme illustré dans la section 2.5.

### C. Points significatifs des capteurs identifiés

L'ensemble des capteurs identifiés est noté  $\{\mathfrak{J}\} = \{j_1, \dots, j_t\}$  où  $t$  est le nombre de capteurs. Le point significatif d'un capteur  $j, j \in \mathfrak{J}$  est l'observation  $k_j$  qui présente la variance maximale :

$$k_j = \arg \max_k \{Var(\tilde{X}_i^{(j,k)}), \quad i = 1 \rightarrow I\} \quad (2.19)$$

où  $\tilde{X}_i^{j,k} = \frac{X_i^{(j,k)} - m^{(j,k)}}{\sigma^{(j,k)}}$ ,  $X_i^{(j,k)}$  sont les mesures du produit  $i$  à l'observation  $k$  du capteur  $j$ ;  $m^{(j,k)} = mean(X_{i=1 \rightarrow n}^{(j,k)})$ ,  $\sigma^{(j,k)} = std(X_{i=1 \rightarrow n}^{(j,k)})$ . Avec cet algorithme, le point  $(j, k_j)$  porte la dynamique de la dégradation.

La matrice des données réduites contenant les points significatifs de tous les produits est ainsi donnée comme suit :

$$\mathcal{X}_{reduite\_2} = \begin{pmatrix} X_1^{(j_1, k_{j_1})} & X_1^{(j_2, k_{j_2})} & \dots & X_1^{(j_t, k_{j_t})} \\ X_2^{(j_1, k_{j_1})} & X_2^{(j_2, k_{j_2})} & \dots & X_2^{(j_t, k_{j_t})} \\ \vdots & \vdots & \ddots & \vdots \\ X_I^{(j_1, k_{j_1})} & X_I^{(j_2, k_{j_2})} & \dots & X_I^{(j_t, k_{j_t})} \end{pmatrix} \quad (2.20)$$

#### 2.3.2.3 Étape 3 : Génération de l'IS

$\mathcal{X}_{reduite\_2}$  est centrée et réduite pour appliquer l'ACP :

$$\mathcal{X}_{reduite\_2} = T_r P_r^T \quad (2.21)$$

La première composante est considérée comme l'indice de santé  $HI_2$ , il peut être calculé comme :

$$HI_2 = \mathcal{X}_{reduite\_2} P_{r\_2} \quad (2.22)$$

où  $P_{r\_2}$  est le premier vecteur propre.

### 2.3.3 Méthode 3 : Points significatifs combinés avec l'ACP (PS-ACP)

#### 2.3.3.1 Étape 1 : Restructuration des données

La matrice 3D ( $I \times J \times K$ ) devient une matrice 2D ( $(I \times (J \times K))$ ) par un déploiement à la dimension du produit comme illustré dans la Fig. 2.4. Cette restructuration permet de considérer l'ensemble des capteurs et des observations comme variables, c'est donc la structure appropriée pour déterminer les points significatifs communs qui portent l'information de la dégradation.

#### 2.3.3.2 Étape 2 : Réduction des données

L'identification des points significatifs ( $js, ks$ ) est une contribution importante de ce travail de thèse. Cette méthode identifie les points capteur-observation ( $js, ks$ ) qui portent l'information de la dégradation, avec l'idée que les points significatifs ( $js, ks$ ) qui portent la dynamique de dégradation du système sont dans l'ensemble des points ( $j, k$ ). La démarche d'identification est donnée dans la Fig. 2.6. Elle se fait en deux phases : Phase (1) Identification des *points en mouvement* (qui ont une variabilité dans le temps) et Phase (2) Identification des *points significatifs*.

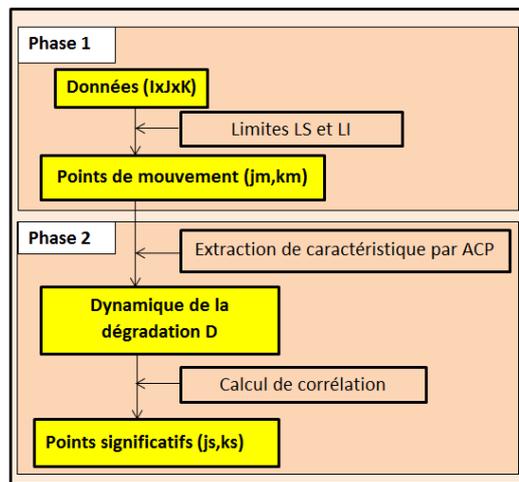


FIGURE 2.6 – Procédure d'identification des points significatifs

#### A. Phase 1 : Identification des points en mouvement

Les deux objectifs de cette phase sont :

- L'élimination des points qui ont une variance quasi nulle pour l'utilisation de l'ACP dans la phase suivante.
- L'identification des points qui ont une variation significative entre les  $n$  premiers produits (considérés *en bonne qualité*) et le produit défectueux.

Les données d'apprentissage sont utilisées pour construire une limite supérieure  $LS$  et une limite inférieure  $LI$  de chaque point  $(j, k)$  en utilisant les équations 2.23 et 2.24 respectivement :

$$LS^{(j,k)} = \max((X_i^{(j,k)}, i = 1, \dots, \mathbf{n}) \quad (2.23)$$

$$LI^{(j,k)} = \min((X_i^{(j,k)}, i = 1, \dots, \mathbf{n}) \quad (2.24)$$

Le dernier produit  $I$ , considéré *défectueux* compte tenu de l'hypothèse (1) est utilisé pour détecter les *points en mouvement*  $(j, k)$  qui vérifient la condition :

$$X_I^{(j,k)} > LS^{(j,k)} \quad \text{ou} \quad X_I^{(j,k)} < LI^{(j,k)} \quad (2.25)$$

Après cette phase, chaque point identifié est noté  $X_i^{(jm, km)}$ ,  $i \in \{1, \dots, I\}$ ,  $(jm, km) \in \{(1_{jm}, 1_{km}), \dots, (M_{jm}, M_{km})\}$ ,  $M$  est le nombre de points identifiés. Ils sont arrangés dans une nouvelle matrice  $\mathcal{X}$  :

$$\mathcal{X} = \begin{pmatrix} X_1^{(1_{jm}, 1_{km})} & X_1^{(2_{jm}, 2_{km})} & \dots & X_1^{(M_{jm}, M_{km})} \\ X_2^{(1_{jm}, 1_{km})} & X_2^{(2_{jm}, 2_{km})} & \dots & X_2^{(M_{jm}, M_{km})} \\ \vdots & \vdots & \ddots & \vdots \\ X_I^{(1_{jm}, 1_{km})} & X_I^{(2_{jm}, 2_{km})} & \dots & X_I^{(M_{jm}, M_{km})} \end{pmatrix} \quad (2.26)$$

Les points en mouvement peuvent être également identifiés par les indices de détection comme EPQ, Hotelling's T-carré et l'indice combiné  $\varphi$  après une ACP. Un test est proposé dans la section suivante *Exemple d'illustration* pour comparer l'ensemble des points en mouvement déterminés en utilisant l'indice combiné  $\varphi$  comparé aux points identifiés par les limites  $LS$  et  $LI$ . Ce test montre que plus de 80% des points de ces deux ensembles sont identiques. Cela implique que ces deux approches sont plutôt équivalentes. Cependant, le calcul par l'approche basée sur les limites  $LS$  et  $LI$  est moins long et plus efficace.

### B. Phase 2 : Identification des points significatifs

$\mathcal{X}$  est centrée et réduite (moyenne nulle et écart-type unitaire) puis décomposée par l'ACP comme suite :

$$\mathcal{X} = T \times P^T \quad (2.27)$$

où  $T$  et  $P$  sont respectivement la matrice des composantes principales et la matrice des vecteurs propres. Les caractéristiques principales de la machine portées par les données sont : les dérives graduelles qui représentent la dégradation (compte tenu de l'hypothèse (1)), les variations brusques, le bruit et les perturbations ; parmi ces caractéristiques, seules les dérives graduelles et le bruit se manifestent en permanence, ils sont donc capturés par la première composante principale, notée  $\mathcal{D}$ .

Les mesures des produits de chaque point en mouvement  $(jm, km)$  sont organisées dans un ordre chronologique (dans l'ordre de passage des produits sur l'équipement) dans une colonne de la matrice  $\mathcal{X}$ , notée  $\mathcal{X}^{(jm, km)}$ . Parmi ces points, certains ont une tendance croissante, d'autre ont une tendance décroissante, le reste des points sont ceux dont

l'évolution ne décrit pas la dégradation. Étant donné que  $\mathcal{D}$  porte la dynamique de la dégradation, la valeur absolue de la corrélation entre  $\mathcal{D}$  et les points du vecteur  $\mathcal{X}^{(jm,km)}$  qui ne décrivent pas la dégradation est plus petite que celles entre  $\mathcal{D}$  et le vecteur  $\mathcal{X}^{(jm,km)}$  qui décrivent la dégradation. Ainsi, la valeur absolue de la corrélation, notée  $c^{(jm,km)}$ , entre chaque point de  $\mathcal{X}^{(jm,km)}$  et  $\mathcal{D}$ , est calculée par l'équation (2.28) pour isoler les points qui portent la dégradation.

$$c^{(jm,km)} = \frac{1}{I} \left| \frac{(\mathcal{X}^{(jm,km)})^T - m_{(jm,km)} \mathbb{I}_{(1,I)} \times (\mathcal{D} - m_{\mathcal{D}} \mathbb{I}_{(I,1)})}{d_{(jm,km)} d_{\mathcal{D}}} \right| \quad (2.28)$$

où  $m_{(jm,km)}$  est la moyenne de la colonne  $\mathcal{X}^{(jm,km)}$ ,  $d_{(jm,km)}$  est l'écart-type de la colonne  $\mathcal{X}^{(jm,km)}$ ,  $m_{\mathcal{D}}$  est la moyenne de  $\mathcal{D}$ ,  $d_{\mathcal{D}}$  l'écart-type de  $\mathcal{D}$ ,  $\mathbb{I}_{(1,I)}$  est un vecteur unitaire de taille  $1 \times I$ ,  $\mathbb{I}_{(I,1)}$  est un vecteur unitaire de taille  $I \times 1$  et  $I$  est le nombre des produits. Comme  $\mathcal{X}$  est centrée et réduite,  $m_{(jm,km)} = 0$ ,  $d_{(jm,km)} = 1 \quad \forall (jm, km)$  et  $m_{\mathcal{D}} = 0$  car  $D$  est la première composante principale de  $\mathcal{X}$ ,  $c^{(jm,km)}$  est donc réécrit comme :

$$c^{(jm,km)} = a |\mathcal{X}^{(jm,km)^T} \times \mathcal{D}| \quad (2.29)$$

où  $a = 1/(I * d_{\mathcal{D}})$  est une constante. Notons  $C$  l'ensemble de toutes les valeurs  $c^{(jm,km)}$ . Pour identifier les points significatifs, un *percentile*  $p^{th}$  de  $C$  est calculé et considéré comme une limite inférieure. Les points significatifs sont ceux qui vérifient l'expression 2.30 :

$$(jm, km) : c^{(jm,km)} > \text{percentile}_{p^{th}} \{C\} \quad (2.30)$$

La valeur du  $p^{ime}$  percentile dépend du cas d'application. Les points significatifs sont notés  $(js, ks)$  et leur mesures sont organisées dans une nouvelle matrice notée  $\mathcal{X}_{reduite\_3}$  :

$$\mathcal{X}_{reduite\_3} = \begin{pmatrix} X_1^{(1_{js}, 1_{ks})} & X_1^{(2_{js}, 2_{ks})} & \dots & X_1^{(S_{js}, S_{ks})} \\ X_2^{(1_{js}, 1_{ks})} & X_2^{(2_{js}, 2_{ks})} & \dots & X_2^{(S_{js}, S_{ks})} \\ \vdots & \vdots & \ddots & \vdots \\ X_I^{(1_{js}, 1_{ks})} & X_I^{(2_{js}, 2_{ks})} & \dots & X_I^{(S_{js}, S_{ks})} \end{pmatrix} \quad (2.31)$$

où  $X_i^{(js, ks)}$ ,  $i \in \{1, \dots, I\}$ ,  $(js, ks) \in \{(1_{js}, 1_{ks}), (2_{js}, 2_{ks}), \dots, (S_{js}, S_{ks})\}$  est la valeur de la mesure du produit  $i$  du capteur  $js$  et de l'observation  $ks$ , avec  $S$  est le nombre des points significatifs  $(js, ks)$ .

### 2.3.3.3 Étape 3 : Génération de l'IS

De la même façon,  $\mathcal{X}_{reduite\_3}$  est centrée et réduite pour appliquer l'ACP :

$$\mathcal{X}_{reduite\_3} = T_r P_r^T \quad (2.32)$$

La première composante est considérée comme l'indice de santé  $HI_3$ .

$$HI_3 = \mathcal{X}_{reduite\_3} P_{r\_3} \quad (2.33)$$

où  $P_{r\_3}$  est le premier vecteur propre.

### 2.3.4 Validation du choix de la première composante principale

Dans l'Etape 3 de l'ensemble des trois méthodes ci-dessus, seule la première composante principale (1ère CP) est considérée comme l'indice de santé. Dans cette section, une démonstration formelle et une illustration numérique sont proposées pour justifier ce choix.

Notons que dans l'Etape 3, la matrice de données réduite ne contient que les mesures sur les variables identifiées (elles sont les capteurs identifiés dans la méthode DR-ACP et DR-ACPM ou les points capteur-observation significatifs dans la méthode SP-ACP). Par conséquent, la matrice réduite obtenue peut être représentée comme suit :

$$\mathcal{X}_{reduite} = \left( \begin{array}{ccc|ccc|ccc} X_1^{v_1} & \dots & X_1^{v_m} & X_1^{v_{m+1}} & \dots & X_1^{v_{m+p}} & X_1^{v_{m+p+1}} & \dots & X_1^{v_{m+p+s}} \\ X_2^{v_1} & \dots & X_2^{v_m} & X_2^{v_{m+1}} & \dots & X_2^{v_{m+p}} & X_2^{v_{m+p+1}} & \dots & X_2^{v_{m+p+s}} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ X_I^{v_1} & \dots & X_I^{v_m} & X_I^{v_{m+1}} & \dots & X_I^{v_{m+p}} & X_I^{v_{m+p+1}} & \dots & X_I^{v_{m+p+s}} \end{array} \right) \quad (2.34)$$

où  $(m + p + s)$  est le nombre des variables identifiées. Les  $m$  premières colonnes sont réellement liées à la dégradation, les  $p$  colonnes suivantes sont affectées par les perturbations qui sont corréées entre elles et les  $s$  dernières colonnes sont affectées par d'autres phénomènes. Notons que l'ACP n'est pas influencée par l'ordre des colonnes. Chaque colonne est centrée et réduite pour donner une même grandeur d'effet sur l'indice de santé extrait. L'ACP est utilisée pour extraire la 1ère CP. Compte-tenu des hypothèses retenues dans la section 2.2,  $m > p \geq 1$ . Les  $s$  dernières variables peuvent être considérées indépendantes les unes des autres. Si certaines parmi elles sont corréées, on peut les arranger dans un autre bloc après le bloc des  $p$  colonnes ; cela n'affecte pas le résultat de la première composante principale.

**△ Démonstration formelle :** Pour valider le choix de la 1ère CP, revenons aux étapes nécessaires au calculs de ces CP.

Premièrement, la matrice de corrélation est calculée. Comme les variables  $\{v_1, v_2, \dots, v_m\}$  sont toutes liées à la dégradation, leur corrélation  $\approx 1$ . les variables  $\{v_{m+1}, v_{m+2}, \dots, v_{m+p}\}$  sont toutes liées aux perturbations qui sont corréées entre elles, leur corrélation  $\approx 1$ . Comme les variables  $\{v_{m+p+1}, \dots, v_{m+p+s}\}$  sont indépendantes les unes des autres et indépendantes des  $m + p$  premières variables, la valeur de leur corrélation est presque nulle. Les valeurs sur la diagonale sont égales 1 car c'est l'auto-corrélation des variables. Pour faciliter la compréhension, une représentation simplifiée de la matrice de corrélation  $\Sigma$  et

donnée en remplaçant par 1 les valeurs  $\approx 1$  et par 0 les valeurs quasiment nulles :

$$\Sigma = \left( \begin{array}{ccc|ccc|ccc} 1 & \dots & 1 & 0 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 1 & \dots & 1 & 0 & \dots & 0 & 0 & \dots & 0 \\ \hline 0 & \dots & 0 & 1 & \dots & 1 & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & 1 & \dots & 1 & 0 & \dots & 0 \\ \hline 0 & \dots & 0 & 0 & \dots & 0 & 1 & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & 0 & \dots & 0 & 0 & \dots & 1 \end{array} \right) \quad (2.35)$$

Pour calculer les composantes principales, il nous faut calculer les valeurs propres et les vecteurs propres de  $\Sigma$ . Les valeurs propres  $\lambda$  sont les racines de l'équation 2.36 :

$$|\Sigma - \lambda \mathbb{I}_{m+p+s}| = 0 \quad (2.36)$$

où  $|\cdot|$  est le déterminant de la matrice et  $\mathbb{I}_{m+p+s}$  est la matrice d'identité de taille  $(m+p+s)$ .

Notons  $\mathcal{A}$  la sous-matrice en haut à gauche de  $\Sigma$  et  $\mathcal{B}$  la sous-matrice au centre de  $\Sigma$ . Ce sont respectivement une matrice carrée de taille  $m$  et une matrice carrée de taille  $p$  dont toutes les valeurs sont égales à 1. La sous-matrice en bas à droite de  $\Sigma$  est une matrice identité de taille  $s$ . L'équation 2.36 peut être réécrite comme suit :

$$|\mathcal{A} - \lambda \mathbb{I}_m| \times |\mathcal{B} - \lambda \mathbb{I}_p| \times (1 - \lambda)^s = 0 \quad (2.37)$$

En utilisant un raisonnement par récurrence on obtient :

$$|\mathcal{A} - \lambda \mathbb{I}_m| = (-\lambda)^{m-1}(m - \lambda) \quad (2.38)$$

$$|\mathcal{B} - \lambda \mathbb{I}_p| = (-\lambda)^{p-1}(p - \lambda) \quad (2.39)$$

L'équation 2.36 peut alors s'écrire comme suit :

$$\begin{aligned} |\Sigma - \lambda \mathbb{I}_{m+p+s}| &= 0 \\ (-\lambda)^{m-1}(m - \lambda)(-\lambda)^{p-1}(p - \lambda)(1 - \lambda)^s &= 0 \end{aligned} \quad (2.40)$$

Ainsi, les valeurs propres dans l'ordre décroissant sont :

$$\{m, p, \underbrace{1, \dots, 1}_s, \underbrace{0, \dots, 0}_{m+p-2}\}$$

La valeur propre maximale est donc  $m$  car  $m > p \geq 1$ . On cherche ensuite le vecteur propre unitaire correspondant à la valeur propre  $m$ , noté  $V_1$ .  $V_1$  doit satisfaire la condition suivante :

$$\begin{cases} \Sigma \times V_1 = mV_1 \\ \|V_1\| = 1 \end{cases} \quad (2.41)$$

Compte-tenu de la condition ci-dessus, le vecteur  $V_1$  est :

$$V_1 = \left( \underbrace{\frac{1}{\sqrt{m}}, \dots, \frac{1}{\sqrt{m}}}_m, \underbrace{0, \dots, 0}_{p+s} \right)^T \quad (2.42)$$

La première composante principale, notée  $T_1$ , est donc :

$$T_1 = \mathcal{X}_{reduite} V_1 \quad (2.43)$$

On constate que le vecteur  $V_1$  présente des poids non nuls sur les  $m$  premières variables, donc,  $T_1$  est liée à la dégradation.

De la même façon, le deuxième vecteur propre, noté  $V_2$ , qui est correspondant à la valeur propre  $p$  est présenté comme suite :

$$V_2 = \left( \underbrace{0, \dots, 0}_m, \underbrace{\frac{1}{\sqrt{p}}, \dots, \frac{1}{\sqrt{p}}}_p, \underbrace{0, \dots, 0}_s \right)^T \quad (2.44)$$

Ce vecteur ne porte que les poids non-nuls correspondant aux  $p$  colonnes affectées par les perturbations, ainsi, la deuxième CP ne porte pas d'information de la dégradation.

Les  $s$  vecteurs propres unitaires correspondant à la valeur propre 1 sont donc :

$$\begin{aligned} & \left( \underbrace{0, \dots, 0}_{m+p}, 1, \underbrace{0, \dots, 0}_{s-1} \right)^T \\ & \left( \underbrace{0, \dots, 0}_{m+p+1}, 1, \underbrace{0, \dots, 0}_{s-2} \right)^T \\ & \vdots \\ & \left( \underbrace{0, \dots, 0}_{m+p+s-1}, 1 \right)^T \end{aligned}$$

Les  $(m + p - 2)$  vecteurs propres unitaires correspondant à la valeur propre 0 sont donc :

$$\begin{aligned} & \left( \frac{1}{\sqrt{2}}, -\frac{1}{\sqrt{2}}, \underbrace{0, \dots, 0}_{m+p+s-2} \right)^T \\ & \left( 0, \frac{1}{\sqrt{2}}, -\frac{1}{\sqrt{2}}, \underbrace{0, \dots, 0}_{m+p+s-3} \right)^T \\ & \vdots \\ & \left( \underbrace{0, \dots, 0}_{m-2}, \frac{1}{\sqrt{2}}, -\frac{1}{\sqrt{2}}, \underbrace{0, \dots, 0}_{p+s} \right)^T \end{aligned}$$

$$\left( \underbrace{0, \dots, 0}_m, \frac{1}{\sqrt{2}}, -\frac{1}{\sqrt{2}}, \underbrace{0, \dots, 0}_{p+s-2} \right)^T$$

⋮

$$\left( \underbrace{0, \dots, 0}_{m+p-2}, \frac{1}{\sqrt{2}}, -\frac{1}{\sqrt{2}}, \underbrace{0, \dots, 0}_s \right)^T$$

On constate que les vecteurs propres correspondant aux valeurs propres 0 ou 1 ont cette caractéristique : soit ils présentent pas de poids sur les  $m$  premières variables soit ils contiennent deux poids qui s'annulent. Par conséquent, il n'est pas nécessaire de garder les composantes principales après la première.

### △ Illustration numérique

Dans cet exemple, on suppose qu'on a  $m = 6$  variables qui sont réellement liées à la dégradation. Pour tenir compte de toutes les tendances connues des dégradations, ces variables ont des profils différents : linéaires, concaves et convexes. Elles sont illustrées dans la Fig. 2.7.(a).  $p = 2$  variables affectées par les perturbations et  $s = 2$  variables affectées par d'autres phénomènes, sont illustrées dans la Fig. 2.7.(b). Les figures 2.8.(a) et (b) montrent respectivement les variables des figures 2.7.(a). et 2.7.(b). centrées et réduites. La Fig. 2.8.(a) met en évidence la corrélation entre les variables qui portent la dégradation.

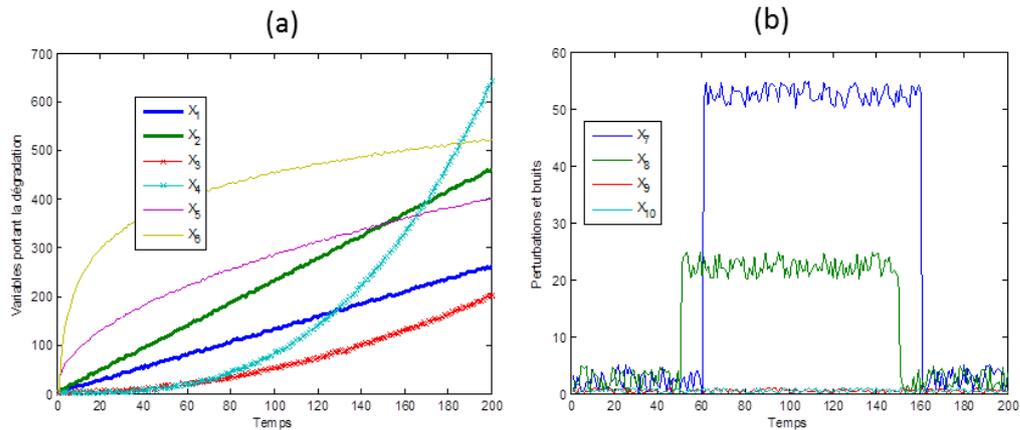


FIGURE 2.7 – Les variables identifiées dans la matrice réduite

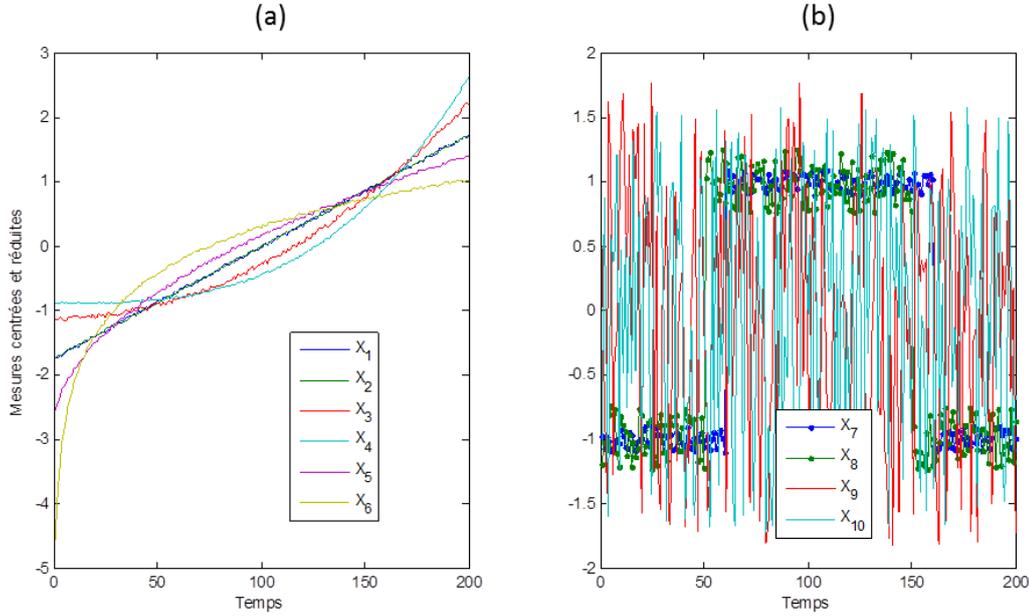


FIGURE 2.8 – Les variables centrées et réduites à une variance unitaire

La matrice de corrélation obtenue est la suivante :

$$\Sigma = \begin{pmatrix} 1 & 0.99 & 0.97 & 0.92 & 0.98 & 0.89 & 0.18 & -0.002 & -0.11 & 0.18 \\ 0.99 & 1 & 0.97 & 0.92 & 0.98 & 0.89 & 0.18 & -0.003 & -0.11 & 0.02 \\ 0.97 & 0.97 & 1 & 0.99 & 0.91 & 0.77 & -0.03 & -0.21 & -0.09 & 0.02 \\ 0.92 & 0.92 & 0.99 & 1 & 0.82 & 0.68 & -0.17 & -0.33 & -0.08 & 0.01 \\ 0.98 & 0.98 & 0.91 & 0.83 & 1 & 0.96 & 0.29 & 0.13 & -0.11 & 0.02 \\ 0.89 & 0.89 & 0.77 & 0.68 & 0.96 & 1 & 0.37 & 0.26 & -0.11 & 0.02 \\ \hline 0.18 & 0.18 & -0.03 & -0.17 & 0.29 & 0.37 & 1 & 0.78 & -0.03 & 0.04 \\ -0.002 & -0.003 & -0.21 & -0.32 & 0.13 & 0.26 & 0.78 & 1 & -0.06 & 0.02 \\ \hline -0.11 & -0.11 & -0.09 & -0.08 & -0.11 & -0.11 & -0.03 & -0.06 & 1 & 0.02 \\ 0.02 & 0.02 & 0.02 & 0.01 & 0.02 & 0.02 & 0.04 & 0.02 & 0.02 & 1 \end{pmatrix}$$

On remarque que la matrice  $\Sigma$  est similaire à celle donnée dans l'équation 2.35. Les valeurs propres de  $\Sigma$  dans l'ordre décroissant sont données comme suit :

$$( 5.62 \mid 2.05 \mid 1.02 \quad 0.97 \mid 0.22 \quad 0.155 \quad 0.015 \quad 0.001 \quad 0.0004 \quad 0.0002 )$$

La valeur propre maximale est approximativement égale à 6 et la deuxième valeur propre est approximativement égale à 2. On voit aussi qu'il y a  $m + p - 2 = 6$  valeurs propres qui sont approximativement égales à 0 et  $s = 2$  valeurs propres approximativement égales à 1. Les composantes principales sont données dans la Fig. 2.9, elle montre que la deuxième CP porte la dynamique des perturbations et seule la 1ère CP porte la dynamique de la dégradation.

La preuve mathématique et cette démonstration permettent de valider le choix de la 1ère composante principale des données réduites comme l'Indice de Santé.

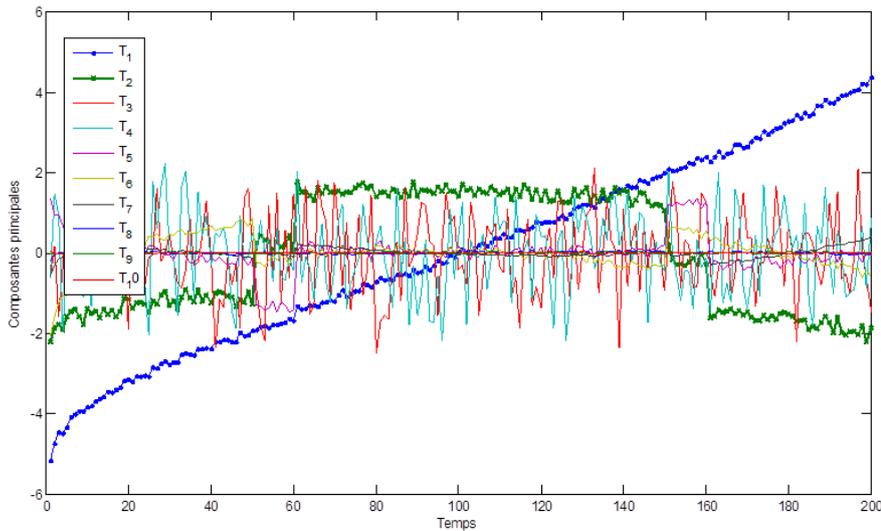


FIGURE 2.9 – Résultat de l'ACP pour la matrice réduite

## 2.4 Comparaison et discussion

Cette section présente une discussion sur les trois méthodes présentées ci-dessus, quatre aspects sont considérés : la nature des données, l'exploitation des données, la détection et l'identification de la dégradation et l'extraction de l'indice de santé.

### Nature des données

Comme ces méthodes présentées se basent sur l'ACP, la Dépendance Linéaire (DL) des données doit être discutée. Toutes les variables dans ces trois méthodes (soit les capteurs soit les observations) sont mesurées sous les effets de la dégradation de l'équipement et dans les mêmes conditions de l'environnement, il y a donc une dépendance linéaire entre ces variables. Ainsi, l'utilisation de l'ACP est appropriée et efficace.

### Exploitation des données

Pour la méthode RD-ACP, l'ensemble de données initiales contenant  $I \times J \times K$  points de mesure est réduit en une matrice de dimension  $I \times J$  ou  $I \times K$ . L'information portée par les observations est donc éliminée avec la structure basée sur les capteurs, et de la même manière, l'information portée par les capteurs est éliminée, à cause de l'utilisation de la moyenne dans le calcul de ces deux structures.

En revanche, les matrices utilisées dans les méthodes RD-ACPM et PS-ACP sont respectivement de dimension  $(I \times K) \times J$  et  $I \times (J \times K)$ , elle conservent donc toute l'information portée par le tenseur de départ.

## Détection et Identification de la dégradation

Les méthodes RD-ACP et RD-ACPM utilisent des indices quadratiques comme EPQ, T-carré ou  $\varphi$  pour identifier les variables qui portent la dégradation. Ces indices sont la projection des données dans l'espace résiduel, leur limites de contrôle sont une approximation de la distribution chi-carré, cela signifie que les données sont supposées suivre une distribution normale. En revanche, dans la méthode PS-ACP, la limite supérieure  $LS^{(j,k)}$  et la limite inférieure  $LI^{(j,k)}$  sont respectivement le maximum et le minimum des données mesurées des  $n$  premiers produits au point  $(j, k)$ , ces limites prennent en compte le bruit de la mesure et elles ne nécessitent pas la condition d'une distribution normale de données ; cependant, si les données d'apprentissage contiennent des valeurs aberrantes, cela peut causer la non-détection de certains points en mouvement.

L'implémentation des méthodes RD-ACP et RD-ACPM nécessite un temps de calcul important, à cause de l'utilisation de l'EPQ dans la méthode RD-ACP et de la matrice de direction dans la méthode RD-ACPM pour l'identification des variables qui portent la dégradation. Alors que la méthode PS-ACP identifie les points significatifs  $(js, ks)$  en utilisant une classification par percentiles associée à une analyse de corrélation, donc, le calcul est simple et rapide ; cependant, la détermination du  $p^{me}$  percentile dépend de la criticité de l'application considérée, et de l'intervalle de confiance souhaité par l'utilisateur.

L'analyse de corrélation proposée dans la méthode PS-ACP permet une identification plus fine des points significatifs. Par conséquent, l'IS généré par la méthode PS-ACP sera moins affecté par des perturbations que celui généré par les méthodes RD-ACP et RD-ACPM.

## Extraction de l'indice de santé

Les trois méthodes proposées ci-dessus, considèrent la projection des variables identifiées dans la première composante de l'espace principal comme indice de santé. Dans la méthode RD-ACP, les données brutes sont réduites par le calcul de moyennes sur les capteurs ou les observations, ce qui peut induire l'élimination de la variabilité qui représente la dégradation. Dans ce cas, le choix de n'importe quelle composante dans l'étape 3 de la méthode pour caractériser l'indice de santé sera inutile, étant donné que l'information recherchée est déjà éliminée.

Pour les deux méthodes RD-ACP et PS-ACP, le calcul des moyennes n'est pas appliqué ; par ailleurs, un premier traitement est fait pour enlever les points capteur-observation qui présentent une variabilité négligeable. Les points restants présentent une variabilité importante, ils sont donc notamment affectés par la dégradation. Par définition, les composantes principales obtenues par ACP capturent les données à plus grande variabilité, et parmi ces composantes principales, c'est la première CP, qui est la composante dont la variance est la plus grande (une caractéristique de l'ACP). Compte tenu de cette caractéristique et de l'hypothèse (1) (la dégradation est progressive et permanente), le choix de

la première composante principale pour caractériser l'IS peut être justifié. Ce choix a fait l'objet d'une démonstration formelle qui est illustrée par un exemple numérique ; le choix est ensuite validé sur des données expérimentales dans le chapitre 4.

## 2.5 Exemple d'illustration

Cette section présente l'application des méthodes détaillées ci-dessus sur un ensemble de données de simulation générées sur Matlab. Nous avons choisi un exemple de simulation pour l'illustration des méthodes développées dans le but de maîtriser le contenu en information de l'indice de santé, et pouvoir ainsi mettre en évidence les avantages et les limites des méthodes présentées dans ce chapitre.

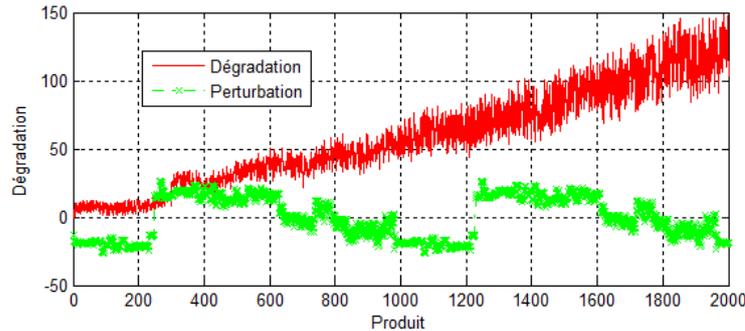


FIGURE 2.10 – Profils de la dégradation et de la perturbation

Pour construire un exemple de données dont toutes les caractéristiques sont connues, nous avons d'abord construit le signal de dégradation et le signal de perturbation présentés dans la Fig. 2.10.

Ces profils sont ensuite répartis dans un ensemble de données de 6 capteurs ( $J = 6$ ), 351

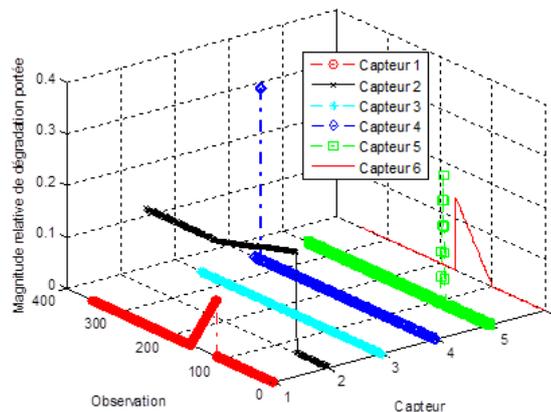


FIGURE 2.11 – Amplitude relative de la dégradation portée par les capteurs et observations

observations ( $K = 351$ ) et 2000 produits ( $I = 2000$ ), avec les amplitudes de la dégradation et de la perturbation portées par les observations et capteurs données respectivement dans les Fig. 2.11 et 2.12. La Fig. 2.11 montre que les capteurs 1, 2 et 6 portent le plus la dégradation, tandis que la Fig. 2.12 montre que les capteurs 1, 3 et 5 portent le plus la perturbation.

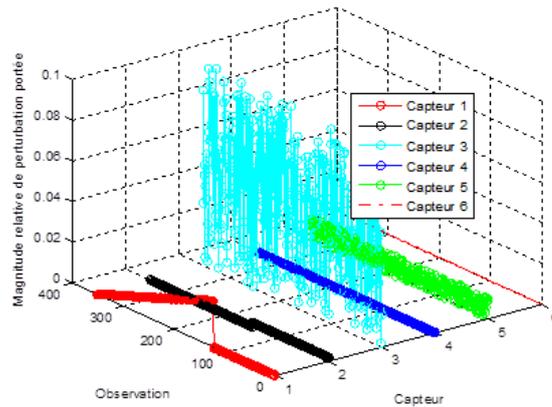


FIGURE 2.12 – Amplitude relative de la perturbation portée par les capteurs et observations

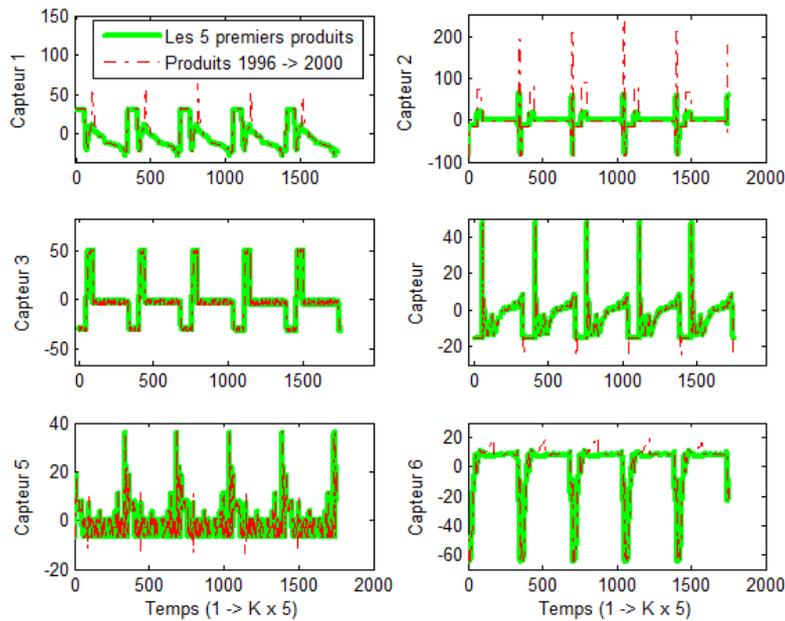


FIGURE 2.13 – Les séquences d'observation des 5 derniers produits comparées à celles des 5 premiers produits

Les séquences d'observation des 6 capteurs sur les 5 derniers produits (du 1996<sup>eme</sup> au 2000<sup>eme</sup>) comparée à celles des 5 premiers produits sont données dans la Fig. 2.13 afin de montrer les points capteur-observation qui sont affectés par la dégradation.

Les observations des capteurs 1 et 2 sont les plus affectées, tandis que celle du capteur 3 ne l'est pas. Le capteur 6 est affecté plus clairement que les capteurs 4 et 5 qui ont seulement quelques observations affectées. Ainsi, les capteurs significatifs, dans l'ordre décroissant de l'impact de la dégradation sont : 2, 1 puis 6.

### 2.5.1 Application de la méthode RD-ACP

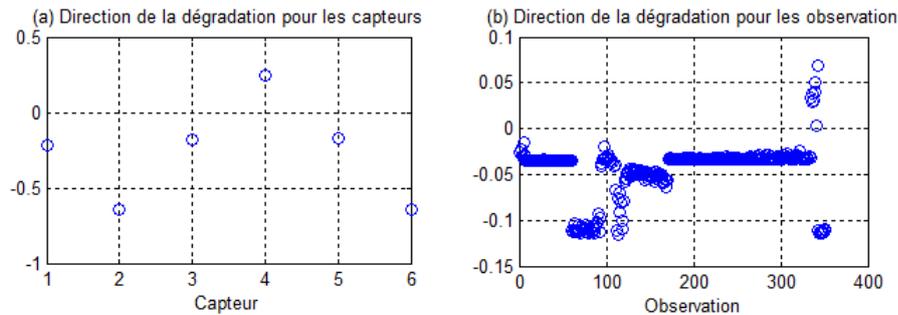


FIGURE 2.14 – Identification de la direction de la dégradation

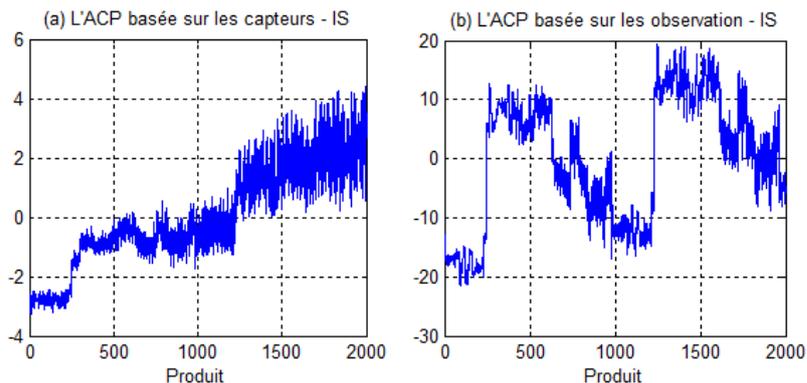


FIGURE 2.15 – L'IS porté par : (a) les capteurs ; (b) les observations

La Fig. 2.14 montre la direction de la dégradation obtenue en appliquant les méthodes de la reconstruction de la dégradation basées respectivement sur les capteurs et les observations. Cette figure montre que les capteurs significatifs sont les capteurs 4, 6 et 2, les observations significatives vont de la 60<sup>eme</sup> à la 150<sup>eme</sup> et de la 335<sup>eme</sup> à la 351<sup>eme</sup>. Les indices de santé générés sont présentés dans la Fig. 2.15, qui montre que le profil de l'IS basé sur les observations est vraiment différent du profil réel de la dégradation.

### 2.5.2 Application de la méthode RD-ACPM

La Fig. 2.16 présente la contribution de l'EPQ des 6 capteurs, elle montre que les capteurs 4 et 6 sont les plus pertinents.

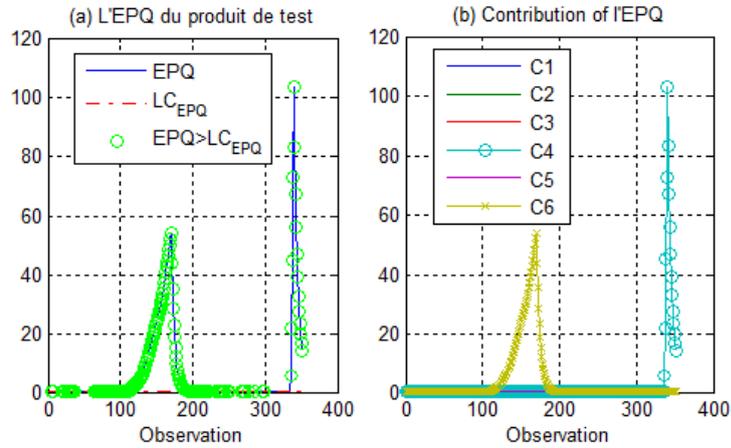


FIGURE 2.16 – Contribution de chaque capteur sur la valeur de l'EPQ

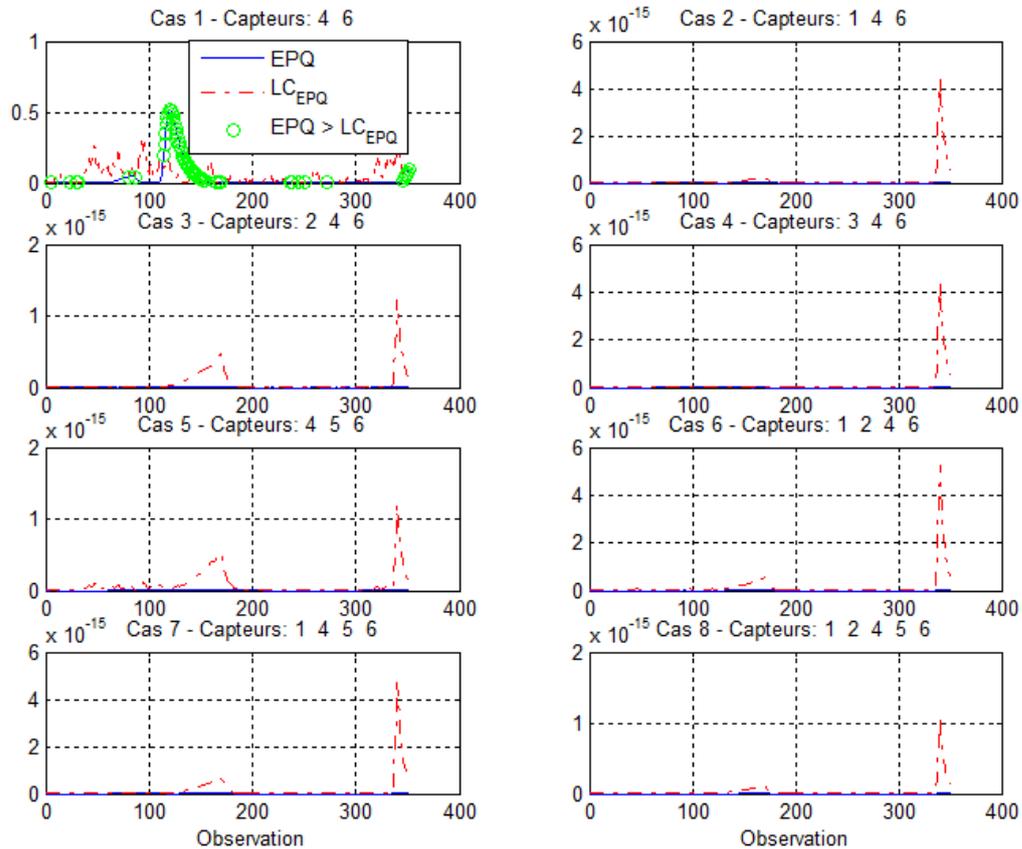


FIGURE 2.17 – Reconstruction de la dégradation de la méthode RD-ACPM

Les capteurs pertinents portent la dégradation, ainsi, l'EPQ après la reconstruction sur ces capteurs devrait être inférieure à la Limite de Contrôle, calculées par les équations 2.17-2.18. Les sous-ensembles de capteurs incluant les capteurs 4 et 6 sont donc utilisés

pour la reconstruction de la dégradation donnée dans la Fig. 2.17, qui montre qu'avec ces deux capteurs (cas 1), la reconstruction ne permet pas d'avoir des valeurs de l'EPQ qui soient toujours inférieures à la limite de contrôle  $LC_{EPQ}$ . Les cas qui donnent un résultat satisfaisant, c'est à dire  $EPQ < LC_{EPQ}$ , avec un nombre minimal de capteurs, sont les cas 2, 3, 4, 5. Cela signifie que un parmi ces quatre cas peut être un ensemble des capteurs pertinents.

Ce résultat est due au fait que dans l'exemple considéré, la dégradation est portée par les capteurs 1, 2, 6 sur plusieurs observations et portée par les capteurs 4, 5 sur quelques observations, tandis que la perturbation est portée par les capteurs 1, 3, 5. Toutefois, on peut choisir un parmi les quatre cas pour générer l'IS. La Fig. 2.18 présente l'IS calculé à partir du cas 2.

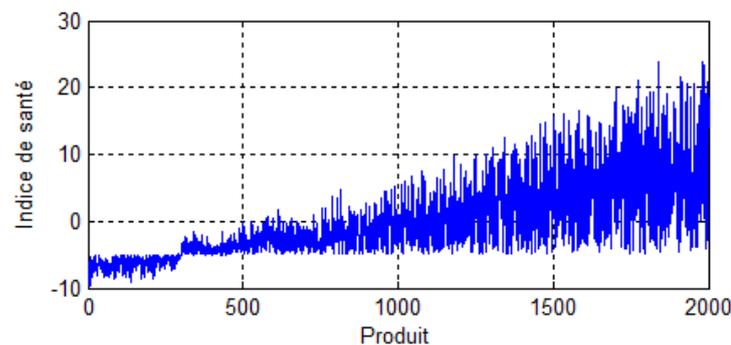


FIGURE 2.18 – L'IS généré par la méthode RD-ACPM

### 2.5.3 Application de la méthode PS-ACP

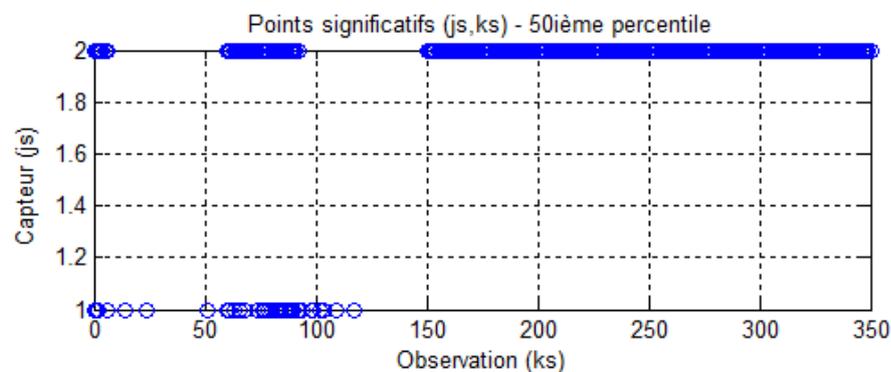


FIGURE 2.19 – Les points significatifs identifiés par la méthode PS-ACP

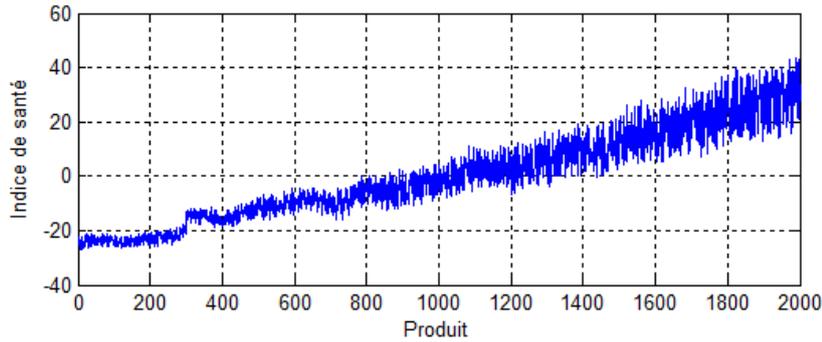


FIGURE 2.20 – L'IS généré par la méthode PS-ACP

La Fig. 2.19 présente les points significatifs identifiés par cette méthode, avec un percentile choisi  $p = 50$ . Ces points sont proches des points qui portent réellement la dégradation et qui sont donnés dans la Fig. 2.10. L'indice de santé généré est donné dans la Fig. 2.20. Son profil est très proche du profil de la dégradation réelle donné dans la Fig. 2.10.

#### 2.5.4 Analyse du résultat

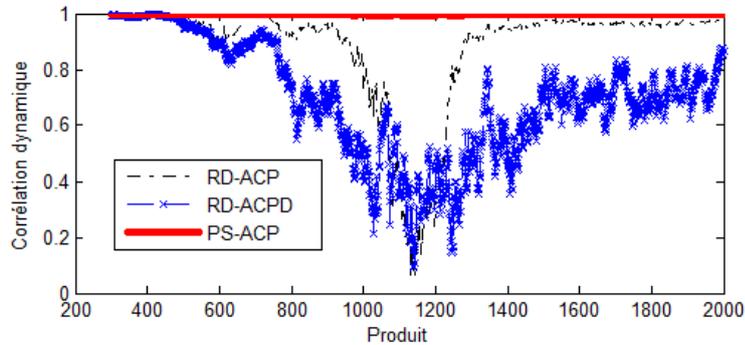


FIGURE 2.21 – La grandeur de la corrélation entre les IS générés par les méthodes proposées et la dégradation réelle

Pour comparer les indices de santé générés par les trois méthodes, la corrélation dynamique<sup>1</sup> entre ces indices et la dégradation réelle est calculée et présentée dans la Fig. 2.21. Ce résultat montre que l'IS généré par la méthode PS-ACP est le plus corrélé avec la dégradation. La comparaison des trois méthodes est résumée dans la Table 2.1.

1. Étant donné 2 signaux  $i$  et  $j$ ,  $\epsilon_{i,t}$  et  $\epsilon_{j,t}$  sont respectivement la valeur des signaux  $i$  et  $j$  après la moyenne centrée et la normalisation unitaire à l'instant  $t$ , la corrélation dynamique entre ces signaux à l'instant  $t$  est  $\rho_{i,j,t} = \frac{\sum_{s=1}^{t-1} \lambda^s \epsilon_{i,t-s} \epsilon_{j,t-s}}{\sqrt{(\sum_{s=1}^{t-1} \lambda^s \epsilon_{i,t-s}^2) (\sum_{s=1}^{t-1} \lambda^s \epsilon_{j,t-s}^2)}}$  [133]

	Adéquation du profil (Corrélation avec la dégradation)	Temps de calcul (Matlab R2012b)	Variables identifiées (L'ordre réel de capteurs pertinents : 2, 1, 6)
RD-ACP basé sur les capteurs	min = 0.11 avg = 0.89	4 secondes	L'ordre de capteurs pertinents : 2, 6, 4 ; pas d'observations
RD-ACP basé sur les observations	No	6 secondes	Observations identifiées ne sont pas claires, pas de capteurs
RD-ACPM	min = 0.07 avg = 0.71	27 secondes	L'ordre de capteurs pertinents : 6, 4
PS-ACP	min = 0.98 avg = 0.998	12 secondes	dépend du choix du percentile, L'ordre de capteurs : 2, 1 avec les observations correspondantes

TABLE 2.1 – Comparaison des trois IS générés

## 2.6 Conclusion

Nous avons présenté dans ce chapitre trois méthodes de génération de l'indice de santé à partir d'un tenseur de données issues des équipements de production en série. Les trois méthodes sont appelées respectivement : Reconstruction de la dégradation par l'Analyse des Composantes Principales (RD-ACP), Reconstruction de la dégradation par l'ACP Multi-voies (RD-ACPM) et les Points significatifs combinés avec ACP (PS-ACP). Ces méthodes sont basées sur l'ACP et contiennent trois étapes : (1) restructuration de la matrice de données, (2) identification des variables pertinentes qui portent les informations de la dégradation et (3) extraction de l'indice de santé à partir des variables identifiées. Un ensemble de données de simulation est construit puis utilisé avec les trois méthodes pour mettre en évidence leurs avantages et leurs limites. En effet, dans l'ensemble de données de simulation, le profil de la dégradation réelle, les variables capteur-observation qui la portent et le profil de la perturbation sont connus, ce qui a permis une analyse comparative à partir des résultats obtenus par l'application de chaque méthode. Ces résultats montrent que la méthode PS-ACP est la plus performante, elle présente un profil d'IS très proche du profil réel de la dégradation, et identifie les points significatifs avec exactitude. Cependant, le choix des percentiles dans l'étape de corrélation devra être formalisé dans les travaux à venir.



# 3

## Pronostic de défaillance

### Sommaire

---

<b>3.1</b>	<b>Pré-traitement</b>	<b>57</b>
3.1.1	Méthodes existantes	57
3.1.2	Proposition : Méthode des percentiles	60
3.1.3	Exemple d'illustration	64
<b>3.2</b>	<b>Estimation du RUL des systèmes à un mode de fonctionnement (Méthode Gamma-percentiles)</b>	<b>72</b>
3.2.1	Modélisation	72
3.2.2	L'estimation de temps de vie résiduel (RUL)	72
3.2.3	Exemple d'illustration	74
	3.2.3.1 Processus de Wiener	75
	3.2.3.2 Processus Gamma	76
	3.2.3.3 Méthode Gamma-percentiles	77
<b>3.3</b>	<b>Estimation du RUL des systèmes à multi-modes de fonctionnement (Modèle IS à multi-modes)</b>	<b>80</b>
3.3.1	Modélisation de l'indice de santé	80
3.3.2	Estimation du RUL	83
3.3.3	Exemple d'illustration	85
<b>3.4</b>	<b>Conclusion</b>	<b>89</b>

---

## Introduction

Ce chapitre présente la modélisation des indices de santé extraits par les méthodes proposées dans le chapitre précédent. Une modélisation appropriée permet de prédire la tendance de l'IS et le RUL avec exactitude. Cependant, il y a peu de méthodes qui permettent de modéliser efficacement des IS bruts noyés dans le bruit, les perturbations et les incertitudes. Ainsi, un pré-traitement est nécessaire afin d'obtenir des profils de dégradation plus exacts à partir des indices de santé bruts. Par conséquent, la première section dans ce chapitre 3.1 présente les outils fréquentiels et statistiques de pré-traitement existant dans la littérature, ainsi qu'une nouvelle méthode développée dans ce travail de thèse, appelée *méthode des percentiles*. Cette méthode tient compte de la variabilité de l'IS brut et permet de générer un ensemble de profils qui décrivent le processus de dégradation. Un exemple d'illustration est présenté pour mettre en évidence les avantages et les limites de chaque méthode.

Ensuite, pour la modélisation de l'IS traité et la prédiction du temps de vie résiduel (RUL), deux sections sont présentées répondant à deux types de problématiques : la section 3.2 est dédiée aux systèmes dont la dynamique est limitée à un seul mode de fonctionnement. Dans cette partie, une nouvelle méthode, appelée *méthode Gamma-percentiles* est proposée pour la modélisation de l'ensemble des profils issus du pré-traitement ci-dessus pour la prédiction du RUL. Dans la section 3.3, nous proposons une méthode de pronostic de défaillance des systèmes à plusieurs modes de fonctionnement. Le modèle développé, appelé *Modèle IS à multi-modes*, tient compte des changements des conditions de fonctionnement du système. Un exemple d'illustration est détaillé à la fin de la section pour montrer l'efficacité de la méthode proposée.

## 3.1 Pré-traitement

Dans la littérature, il existe plusieurs outils de pré-traitement du signal, les plus utilisés sont : des calculs statistiques [138], la Décomposition en Modes Empiriques (DME) [139], les filtres passe-bas [140] et la transformation en ondelettes [141].

Ces outils de pré-traitement sont utilisés dans plusieurs travaux de recherche sur le pronostic de défaillance, comme par exemple dans la prédiction du RUL à partir des données du 2008 PHM Data Challenge qui contient des mesures chronologiques de plusieurs capteurs, où [143] a utilisé un modèle régressif pour extraire l'IS à partir de cet ensemble de données. [138] utilise des indices statistiques pour extraire les caractéristiques sensibles à la défaillance et robustes au bruit à partir de données vibratoires des pompes de sables bitumineux. [137] utilise également ces indices statistiques sur les données brutes mesurées sur des roulements. [144] applique la DME sur des signaux vibratoires des roulements pour identifier et diagnostiquer des défauts. Pour le diagnostic des défauts des roulements à partir des signaux d'accélération, [145] applique un filtrage avec plusieurs niveaux de bande-passante pour améliorer le rapport signal-bruit. Concernant l'application de la transformation en ondelettes, [146] l'applique sur les données de tension des éléments de roulement d'une boîte de vitesse pour caractériser des symptômes de fatigue précoce et de fissure. [159] applique la décomposition en ondelettes pour extraire un profil monotone à partir d'un indice de santé bruité. Une synthèse de ces méthodes est présentée ci-dessous qui couvrent une grande variété des techniques existantes. Ensuite, une nouvelle méthode de pré-traitement, basée sur le concept des percentiles, et qui permet de prendre en compte les incertitudes et la tendance de l'IS est développée dans cette section. Enfin, une étude comparative est présentée à la fin de ce chapitre en se basant sur les critères suivants : le temps de calcul, l'erreur d'estimation, l'intervalle de confiance, le profil de l'IS selon des conditions d'utilisation et la complexité de la mise en place.

### 3.1.1 Méthodes existantes

#### Indices statistiques

La dégradation peut être extraite dans le domaine temporel ou fréquentiel. La dégradation étant supposée permanente, progressive et noyée dans les bruits et les perturbations, l'utilisation des méthodes temporelles est plus appropriée. Les indices temporels les plus utilisés dans la littérature sont présentés dans la Table 3.1 ([137], [138]) où  $n$  est la longueur de la fenêtre mobile de calcul.

Pour la mise en évidence des tendances progressives dans le diagnostic et pronostic, les indices Valeur quadratique moyenne (Root Mean Square ( $RMS$ )), Valeur de pic (Peak value ( $Pv$ )) et la somme  $\sum_{i=1}^n |x_i|$  sont les plus adaptés. L'indice  $Vk$  (Valeur de Kurtosis) est inversement proportionnel à la  $RMS$ , il ne peut donc pas décrire la dégradation. L'indice  $Sk$  est une division de deux quantités qui représentent la dispersion de la fenêtre mobile autour de sa valeur moyenne, donc, il ne décrit pas non plus la tendance. Les indices  $Fc$ ,  $Fd$ ,  $Fi$  et  $Ff$  sont des divisions de deux quantités croissantes dans la même

Valeur quadratique moyenne en anglais <i>Root Mean Square</i> (RMS)	$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$
Écart-type en anglais <i>Standard deviation</i> (Std)	$Std = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
Valeur de Kurtosis	$Vk = \frac{1/n \sum_{i=1}^n (x_i - \bar{x})^4}{RMS^4}$
Skewness	$Sk = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)Std^3}$
Valeur de pic en anglais <i>Peak value</i> (Pv)	$Pv = \frac{1}{2}[\max(x_i) - \min(x_i)]$
Facteur de crête	$Fc = Pv/RMS$
Facteur de dégagement	$Fd = \frac{Pv}{\left(\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i }\right)^2}$
Facteur d'impulsion	$Fi = \frac{Pv}{1/n \sum_{i=1}^n  x_i }$
Facteur de forme	$Ff = \frac{RMS}{1/n \sum_{i=1}^n  x_i }$

TABLE 3.1 – Des indices statistiques dans le domaine temporel

grandeur, ils ne peuvent donc pas représenter la dynamique irréversible de la dégradation.

### Décomposition en modes empiriques (DME)

Cette technique est proposée par Huang et al. [139], pour décomposer un signal en un ensemble de Fonctions de Modes Intrinsèques (FMI). Cette approche empirique est résumée dans les étapes suivantes :

1. Identification des extremums locaux
2. Jonction de tous les maximums locaux par une courbe cubique pour former une enveloppe supérieure  $e_{max}$
3. Répétition de la même procédure pour les minimums locaux, pour obtenir une enveloppe inférieure  $e_{min}$ . La moyenne de ces enveloppes est notée  $m_1 = (e_{max} + e_{min})/2$
4. Calcul du résidu  $h_1$  comme suit :

$$h_1 = X - m_1 \tag{3.1}$$

Une fois  $h_1$  calculé, il peut être considéré comme le signal original puis les étapes (1), (2), (3), (4) sont répétées  $k$  fois comme suit :

$$h_1 - m_{1,1} = h_{1,1} \quad (3.2)$$

$$\dots \quad (3.3)$$

$$h_{1,k-1} - m_{1,k} = h_{1,k} \quad (3.4)$$

Un critère d'arrêt du processus de filtrage est proposé par Huang [139]. Le processus s'arrête quand une valeur  $SD_k$  devient inférieure à une valeur prédéfinie, avec  $SD_k$  calculé par l'équation 3.5 :

$$SD_k = \frac{\sum t = 0^T |h_{k-1}(t) - h_k(t)|^2}{\sum t = 0^T h_{k-1}^2(t)} \quad (3.5)$$

$h_{1,k}$  est considéré comme la première FMI des données :

$$c_1 = h_{1,k} \quad (3.6)$$

Le résidu  $r_1$  est l'information restante après élimination de  $c_1$  :

$$r_1 = X - c_1 \quad (3.7)$$

$r_1$  est ensuite traité avec la même procédure de filtrage. A la  $n^{me}$  itération, on obtient :

$$r_n = r_{n-1} - c_n \quad (3.8)$$

La procédure de filtrage s'arrête lorsque le résidu  $r_n$  obtenu est monotone. Ainsi l'ensemble des données de départ peut être défini comme suit :

$$X = \sum_{i=1}^n c_i + r_n \quad (3.9)$$

Cette méthode décompose des signaux en différentes composantes dans le domaine temporel. Pour l'appliquer, une valeur prédéfinie du critère d'arrêt et les niveaux de FMI que contient le signal de sortie sont les deux points nécessaires à définir, mais il n'existe pas de méthodes pour le faire.

### Filtres passe-bas

Le filtre passe-bas est un outil efficace pour éliminer les composantes indésirables d'un signal, comme les perturbations et le bruit, en éliminant les fréquences liées à ces composantes par la définition d'une fréquence de coupure [140]. En général, dans un signal de dégradation, le bruit est en hautes fréquences et les perturbations sont à des fréquences plus basses, un profil monotone de dégradation est localisé à très basses fréquences. Un filtre passe-bas est basé sur la détermination d'une fréquence de coupure. Le filtre de Butterworth est largement utilisé car il n'engendre pas d'ondulation de gain dans la bande

passante et la bande d'arrêt, il a une réponse de phase assez linéaire. Dans le domaine fréquentiel, il s'écrit :

$$G(\omega) = \sqrt{\frac{G_0^2}{1 + (\omega/\omega_c)^{2n}}} \quad (3.10)$$

où  $\omega_c$  est la fréquence de coupure,  $n$  est le nombre des pôles du filtre et  $G_0$  est le gain à la fréquence nulle ; ces paramètres sont à déterminer.

D'ailleurs, le choix du filtre est soumis aux caractéristiques de filtrage qui sont : l'ondulation sur la bande passante et la bande d'arrêt, la rapidité de la coupure, la réponse de phase linéaire ou non-linéaire. Un bon filtrage revient à trouver le meilleur compromis entre ces caractéristiques.

### Décomposition en ondelettes

La décomposition en ondelettes (DO) décompose un signal en composantes correspondant à différents niveaux de fréquences. A chaque niveau de la transformation, le signal est décomposé en une part de hautes fréquences appelée le détail et une part de basses fréquences appelée l'approximation [141], [142]. La DO est utilisée pour obtenir une approximation dans laquelle le bruit et les perturbation sont réduits autant que possible. La famille d'ondelettes Daubechies est la plus utilisée, nous avons donc choisi d'utiliser l'ondelette Daubechies D8 dans l'analyse comparative présentée dans ce chapitre.

Comme les niveaux de fréquences des bruits et des perturbations différentes en fonction de la nature du signal, la famille d'ondelette et le nombre convenable de niveaux de décomposition sont à définir en fonction de la nature du signal, ce qui représente la complexité de cette méthode.

### 3.1.2 Proposition : Méthode des percentiles

Dans la pratique, la plupart des applications réelles du pronostic de défaillance basé sur un indice de santé montrent que cet indice est fortement bruité. L'indice de santé brut dans ces applications présente une forme commune : un profil monotone noyé dans le bruit. L'indice de santé obtenu peut être considéré comme une synthèse de plusieurs éléments ; un profil monotone (représentant l'évolution de la dégradation), des perturbations, le bruit et certaines valeurs aberrantes ([147], [148], [149], [150], [151]). L'association de ces éléments donne lieu au profil commun d'indice de santé brut présenté dans la Fig. 3.1 sous sa forme normalisée.

La méthode des percentiles est développée dans ce travail pour apporter une solution au problème de la perte d'information engendrée par l'utilisation des méthodes de pré-traitement existantes. Elle permet de prendre en compte la variabilité de données et la densité de l'information. En effet, les méthodes de filtrage telles que la décomposition en

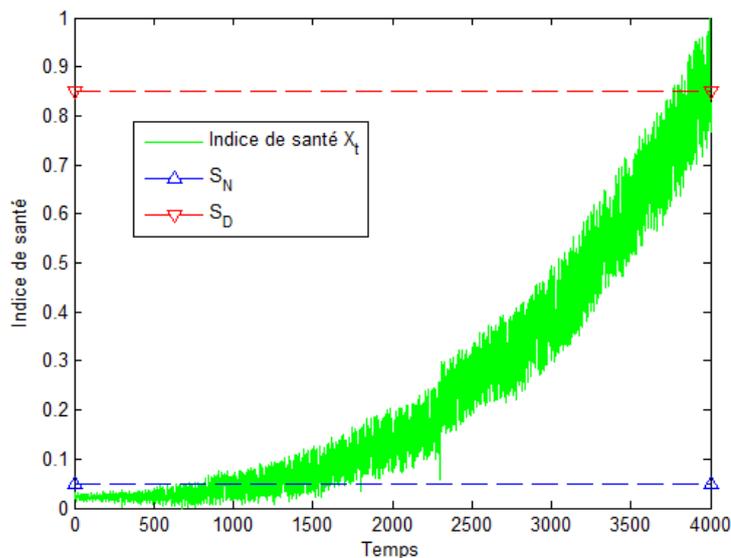


FIGURE 3.1 – Une forme commune de l'IS normalisé

ondelettes et le filtre passe-bas exigent la connaissance de la fréquence qui porte la dégradation pour éviter d'éliminer l'information utile lors du filtrage, mais en cas d'application réelle, cette fréquence n'est pas connue, pas même approximativement. Les méthodes telles que les indices statistiques et la DME sont basées entre autres sur le calcul de la moyenne, ce qui peut conduire à l'élimination de la variabilité liée à la dégradation.

Pour expliquer le principe de la méthode des percentiles, soit l'indice santé brut  $X_t$  de la Fig. 3.1 où  $t$  est le temps,  $X_t$  décrit le processus de dégradation à partir du fonctionnement normal jusqu'à la panne. L'indice de santé est supposé normalisé entre 0 et 1, le seuil de fonctionnement normal  $S_N$  et le seuil défaillance totale  $S_D$  sont prédéfinis comme illustré dans la Fig. 3.1.

La génération des profils monotones à partir de  $X_t$  est résumée par les étapes suivantes :

1. Division de l'intervalle entre  $S_N$  et  $S_D$  en plusieurs niveaux avec un pas  $s \ll 1$  :  
Un ensemble de valeurs  $V = \{S_N, S_N + s, S_N + 2 \times s, \dots, S_D\}$  est obtenu. Le pas doit être assez petit pour garder la résolution des profils explicites et détaillés. Cependant, plus le pas est petit, plus le temps de calcul sera long, ainsi, 0.01 est un bon compromis.
2. Construction de l'ensemble des temps  $T_y$  pour chaque valeur  $y \in V$  comme suit :  
Comme l'indice de santé est bruité,  $X_t$  prend une valeur donnée à plusieurs instants (voir Fig. 3.1). A chaque niveau  $y \in V$ , un ensemble de temps  $T_y = \{t_1, t_2, \dots\}$  est obtenu, dans lequel chaque élément  $t_i$  satisfait la contrainte :

$$(X_{t_i} < y) \quad \& \quad (X_{t_{i+1}} \geq y) \quad (3.11)$$

Pour expliquer la démarche de construction de l'ensemble  $T_y$ , prenons l'exemple de la Fig. 3.2 où l'IS prend la valeur  $y = 0.32$  à plusieurs reprises au fil du temps. Compte tenu de la contrainte 3.11, l'ensemble des temps obtenu est  $T_y = \{t_1, t_2, t_3, t_4, t_5, t_6, t_7\}$ .

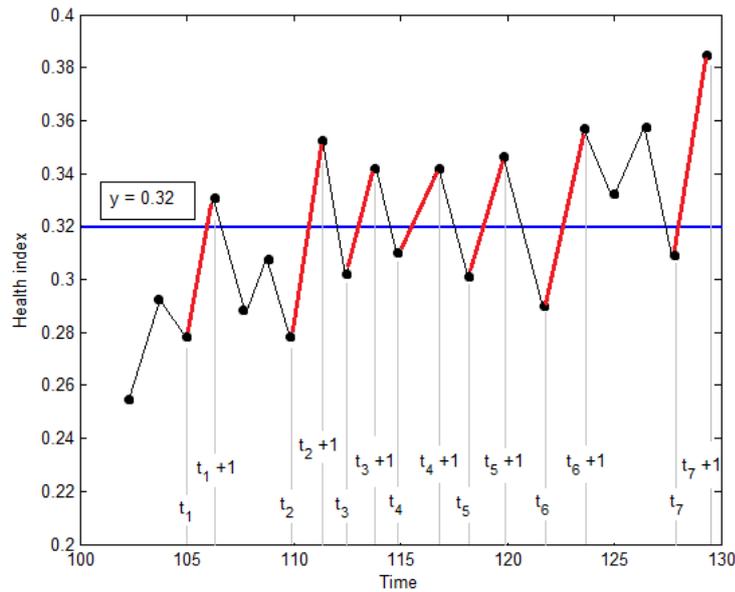
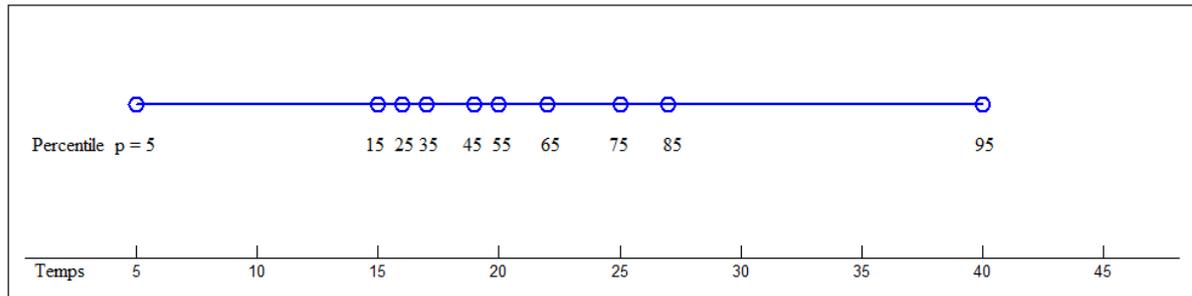


FIGURE 3.2 – IS prend la même valeur à plusieurs instants

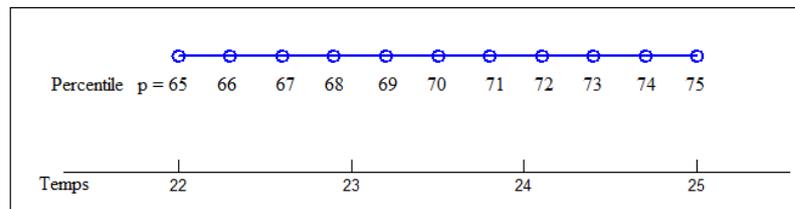
3. Calcul des percentiles  $p, p \in \{1, 2, \dots, 100\}$  pour chaque  $T_y$  :

Le  $p^{ieme}$  percentile pour chaque  $T_y$  est noté  $T_y^p$ . Le calcul du percentile peut être interprété comme un calcul de position relative. Le  $k^{ieme}$  percentile d'un ensemble de  $T_y$  de  $n$  valeurs peut donc être calculé comme suit : [152] :

- Le percentile des valeurs de l'ensemble  $T_y$  dans l'ordre croissant sont respectivement  $100 \times (1 - 0.5)/n$ ,  $100 \times (2 - 0.5)/n$ ,  $\dots$ ,  $100 \times (n - 0.5)/n$ . Pour mieux illustrer ce calcul, prenons l'exemple de la Figure. 3.3.(a), où  $T_y = \{5, 15, 16, 17, 19, 20, 22, 25, 27, 40\}$  et  $n = 10$  valeurs. Leur percentiles sont respectivement :  $\{50/10\}$ ,  $\{150/10\}$ ,  $\{250/10\}$ ,  $\{350/10\}$ ,  $\dots$  et  $\{950/10\}$ .
- Entre ces points, l'interpolation linéaire est utilisée pour calculer les percentiles entre  $100 \times (1 - 0.5)/n$  et  $100 \times (n - 0.5)/n$ . Par exemple avec l'ensemble  $T_y$  ci-dessus, on calcule les  $\{66, 67, \dots, 74\}$ -ième percentiles comme suit : Le 65ième percentile correspond au temps 22 et le 75ième percentile correspond au temps 25. Par l'interpolation linéaire, les valeurs de temps correspondant aux  $\{66, 67, \dots, 74\}$ -ième percentiles sont respectivement :  $\{22.3, 22.6, 22.9, 23.2, 23.5, 23.8, 24.1, 24.4, 24.7\}$ , comme illustré la Fig. 3.3.(b).



(a)



(b)

FIGURE 3.3 – Exemple du calcul des percentiles : (a) - Les percentiles correspondants pour les valeurs de  $T_y$  ; (b) - Les valeurs de temps correspondants pour les  $\{66, 67, \dots, 74\}$ -ième percentiles

- La valeur de  $T_p^y$  avec  $p$  en dehors des percentiles ci-dessus sont attribuée à la valeur minimale si  $p < 100 \times (1 - 0.5)/n$  où à la valeur maximale si  $p > 100 \times (n - 0.5)/n$ . Dans cet exemple, la valeur de  $T_p^y$  avec  $p = (1, 2, 3, 4)$  est égale à 5, la valeur de  $T_p^y$  avec  $p = (96, 97, 98, 99, 100)$  est égale à 40.

Cette technique de calcul permet de prendre en compte la densité des points dans chaque ensemble  $T_y$ .

4. Construction d'un profil  $Z^p$  pour chaque percentile  $p, p \in \{1, 2, \dots, 100\}$  comme suit :

Temps	$T_{S_N}^p$	$T_{S_N+s}^p$	$\dots$	$T_{S_D}^p$
Valeur	$S_N$	$S_N + s$	$\dots$	$S_D$

TABLE 3.2 – Profil  $Z^p$ 

On obtient donc 100 profils  $Z^p, p \in \{1, 2, \dots, 100\}$ .

5. Choix des percentiles :

Dans certaines applications, il est nécessaire de retenir plus d'informations que d'autres, cela est associé aux caractéristiques de l'application et des données. Dans

l'exemple de la Fig. 3.4,  $p$  est choisi entre 25 et 75 afin de garder seulement les informations centrées et éliminer les valeurs aberrantes. Il y a donc 51 profils à considérer, ainsi, 51 profils  $Z^p$ ,  $p \in \{25, 26, \dots, 75\}$  sont extraits de  $X_t$  dans cet exemple.

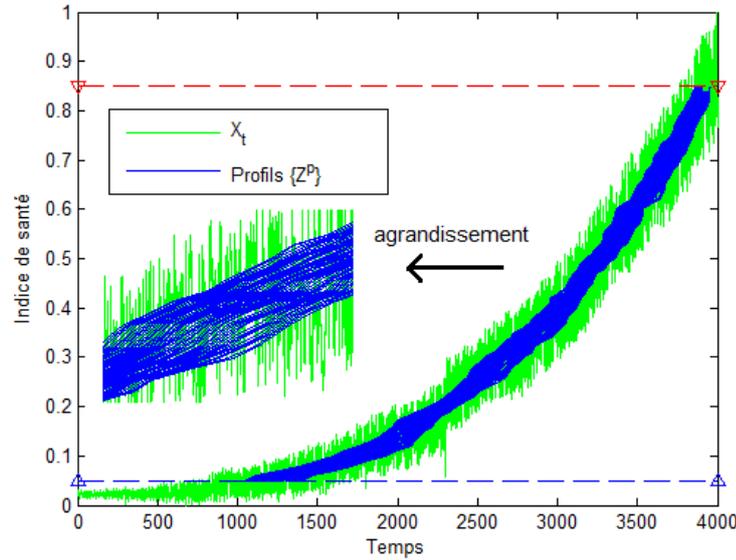


FIGURE 3.4 – 51 profils  $Z^p$  extraits à partir de  $X_t$

Comme le processus de dégradation est supposé monotone et irréversible, les profils extraits doivent être monotones étant donné que l'indice de santé évolue progressivement dans le temps, ainsi, les données sont extraites en respectant la contrainte suivante :  $T_y^p \leq T_{y+0.01}^p$ . Dans le cas où  $T_y^p > T_{y+0.01}^p$ , le point  $(T_{y+0.01}^p, y + 0.01)$  est retiré pour que  $Z^p$  soit monotone. La comparaison des avantages et des limites de cette méthode avec les méthodes existantes est illustrée dans la section 3.1.3, par une application sur l'indice de santé brute extrait dans le chapitre précédent.

### 3.1.3 Exemple d'illustration

Cette section présente l'application des méthodes de pré-traitement et de pronostic présentées ci-dessus sur l'indice de santé brut généré dans le chapitre précédent (Fig. 2.20). Rappelons que cet IS contient du bruit, une variabilité croissante, des perturbations sinusoïdales (fréquence de 1/150 et 1/250) et brusques et un profil monotone, comme montré dans la Fig. 3.5. Le profil monotone est considéré comme étant la dégradation, il est donc utilisé comme référence pour évaluer la performance de ces méthodes. L'IS de la Fig. 3.5 décrit une forme unimodale (UM), un autre IS qui représente une forme multimodale (MM) est également utilisé, comme illustré dans la Fig. 3.6. Cette IS est issu des données d'un système qui fonctionne sur plusieurs modes. Les IS utilisés sont normalisés entre 0 et 1.

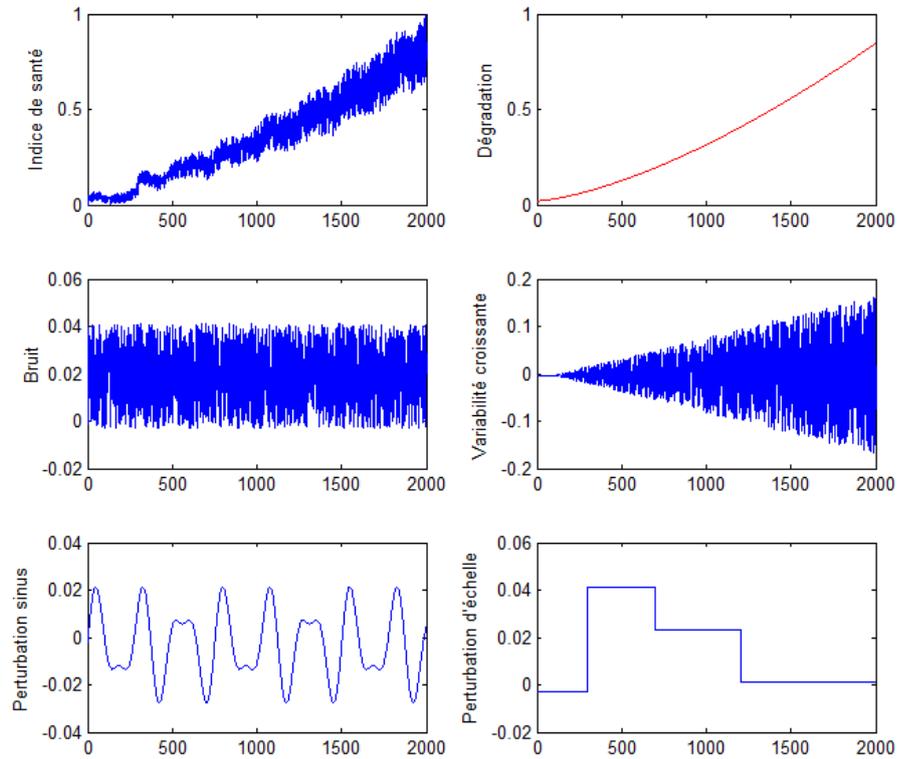


FIGURE 3.5 – Les composantes de l'indice de santé brut

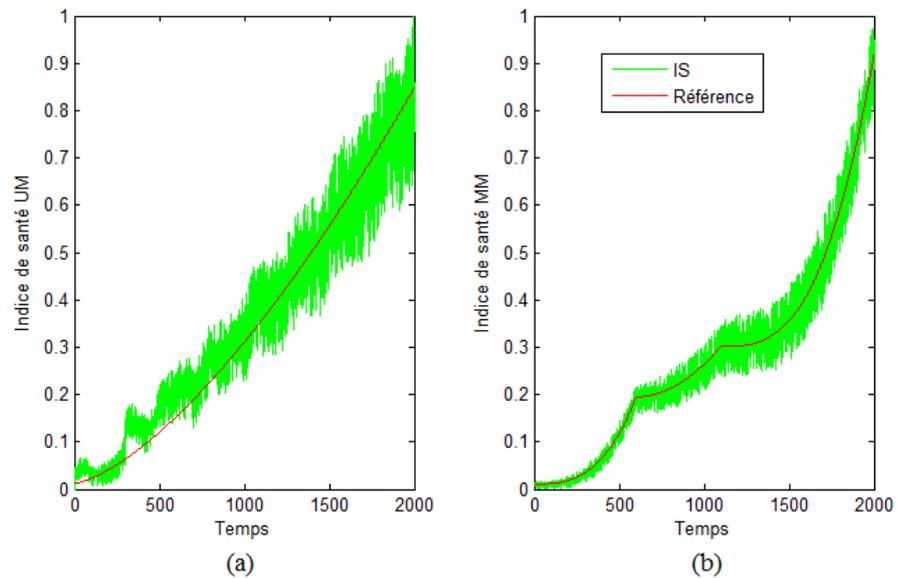


FIGURE 3.6 – Deux profils de l'IS : (a) Unimodale ; (b) Multimodale

### Indices statistiques

La longueur de la fenêtre mobile est choisie  $n = 10$ . La Fig. 3.7.(a) donne les résultats de l'application des outils statistiques : indice moyenne quadratique ( $RMS$ ), écart-type

(*Std*) et valeur de crête (*Pv*) sur l'IS UM. Parmi ces outils statistiques, l'indice de santé extrait par RMS est le plus proche de la référence. L'erreur maximale d'approximation est de 0.09, cependant, cet indice n'est pas monotone et sensible aux perturbations. Le résultat obtenu sur l'indice de santé MM est donné dans la Fig. 3.7.(b) qui donne lieu à une même conclusion. L'erreur maximale est de 0.03 pour l'indice *RMS*. Les résultats obtenus montrent également que l'indice RMS sur l'IS UM présente une variabilité et des perturbations plus importantes que sur l'IS MM. La raison est que les perturbations et la variabilité de l'IS UM sont plus importantes que celles de l'IS MM. (voir la Fig. 3.6). Cet indice est donc sensible à la variabilité des signaux.

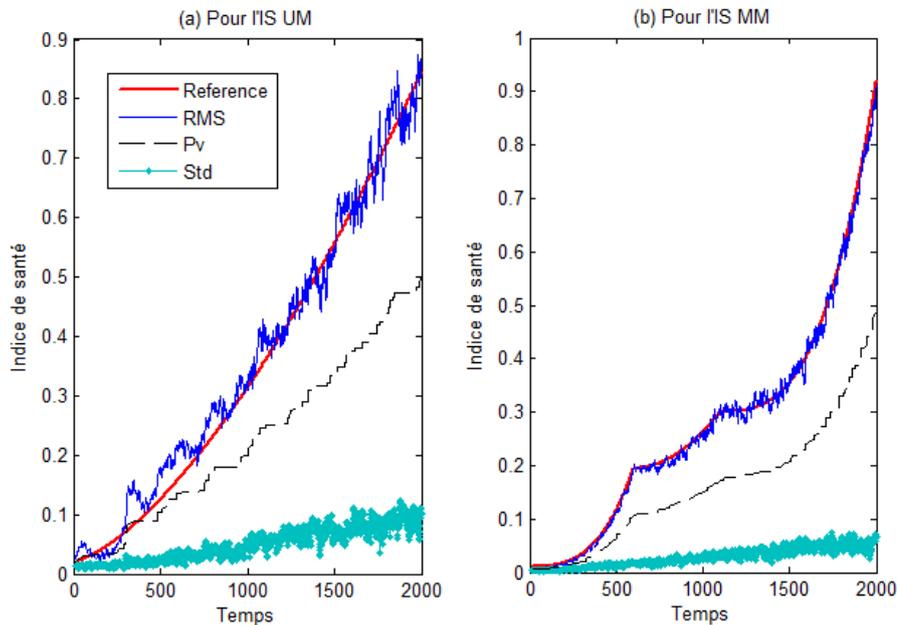


FIGURE 3.7 – Résultat de l'application des outils statistiques sur les IS : (a) Pour l'IS UM, (b) Pour l'IS MM

### Décomposition en modes empiriques (DME)

La Fig. 3.8 présente le résultat de l'application de la technique DME sur les IS avec trois niveaux de décompositions : niveaux 7, 8 et 9 correspondant aux résidus  $r_7$ ,  $r_8$  et  $r_9$ . La Fig. 3.8.(a) montre le résultat obtenu sur l'IS UM et la Fig. 3.8.(b) présente celui obtenu sur l'IS MM. Les résultats obtenus dans les deux cas sont similaires : leurs profils sont proches de la référence, les profils niveaux 7 et 8 sont monotones et peu influencés par des perturbations et bruits. Leur maximum d'erreurs sont respectivement :  $[0.08, 0.06, 0.077]$  pour l'IS UM et  $[0.029, 0.037, 0.088]$  pour l'IS MM. Les résultats obtenus montrent que la décomposition aux niveaux 7 et 8 de cette technique est plus affectée par la variabilité des IS que celle au niveau 9 dans cet exemple.

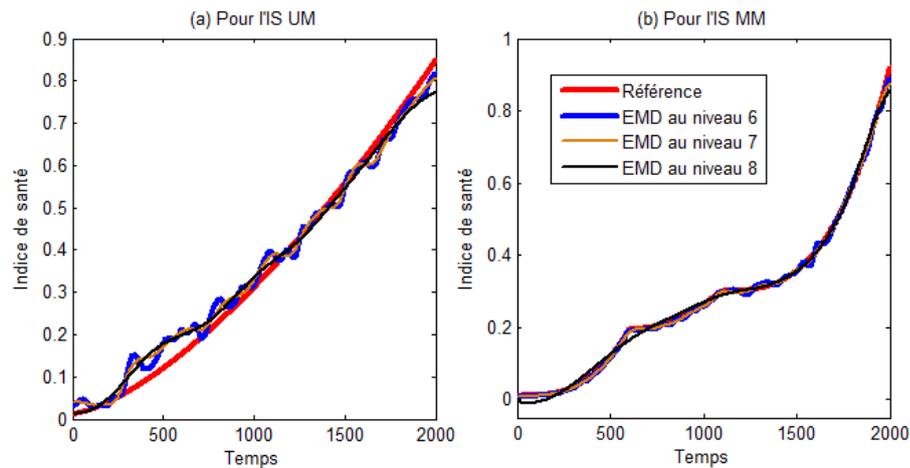


FIGURE 3.8 – Résultat de l'application de la DME sur les IS : (a) Pour l'IS UM, (b) Pour l'IS MM

### Filtre passe-bas

Le filtre de Butterworth avec le nombre des pôles  $n = 10$  est appliqué aux deux indices de santé. Le résultat est donné dans la Fig. 3.9.(a) pour l'IS UM et la Fig. 3.9.(b) pour l'IS MM. Deux fréquences de coupure sont choisies :  $\omega_c = 0.05$  et  $\omega_c = 0.02$ . Pour les deux cas, le profil obtenu avec  $\omega_c = 0.05$  est plus proche de la référence mais aussi plus sensible aux perturbations que celui obtenu avec  $\omega_c = 0.02$ . L'erreur maximale est de 0.08 pour l'IS UM et 0.1 pour l'IS MM. Les profils obtenus avec  $\omega_c = 0.02$  montrent un écart important par rapport à la référence.

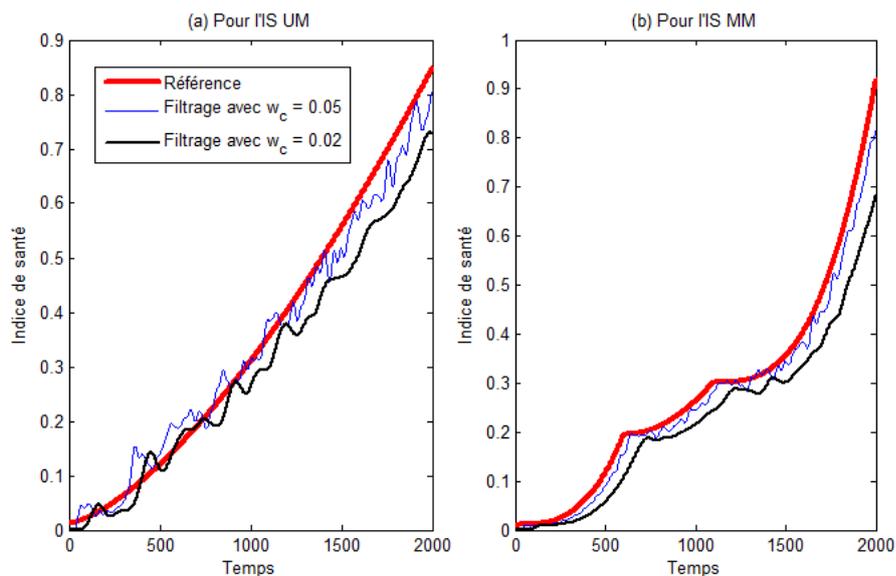


FIGURE 3.9 – Le filtre passe-bas appliqué sur les deux indices de santé : (a) Pour l'IS UM, (b) Pour l'IS MM

### Décomposition en ondelettes (DO)

Le résultat de l'application de la DO avec la famille d'ondelette Daubechies  $D8$  aux niveaux 8, 9 et 10 sur les deux IS est donné dans la Fig. 3.10. Pour l'IS UM, la Fig. 3.10.(a) montre que l'approximation des trois niveaux est proche de la référence, les erreurs maximales sont respectivement : 0.05, 0.04 et 0.06. Avec l'IS MM, la Fig. 3.10.(b) montre que les erreurs maximales sont respectivement : 0.04, 0.07 et 0.11. Les profils obtenus sont monotones.

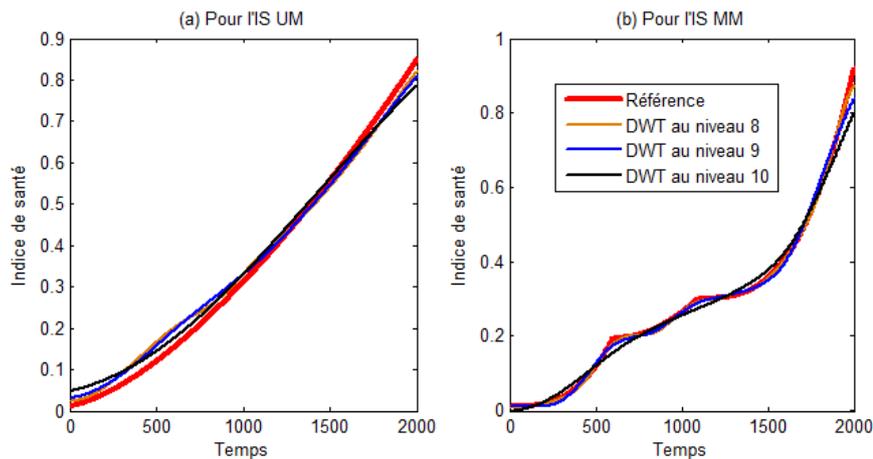


FIGURE 3.10 – L'application de la décomposition en ondelettes sur les deux indices de santé : (a) Pour l'IS UM, (b) Pour l'IS MM

### Méthode des percentiles

Pour cette méthode, les seuils sont choisis :  $S_L = 0.05$  and  $S_U = 0.85$ . Les profils extraits sont du 10<sup>ième</sup> au 90<sup>ième</sup> percentiles. la Fig. 3.11 montre le résultat pour l'indice de santé UM. La ligne moyenne est construite par la procédure suivante : les profils des percentiles du 10<sup>ième</sup> au 90<sup>ième</sup> sont interpolés et extrapolés de l'instant  $t = 0$  à l'instant  $t = 2000$ , la ligne moyenne est calculée entre les deux bornes  $S_L = 0.05$  et  $S_U = 0.85$ . La figure montre que la référence est à l'intérieur de l'intervalle de confiance et proche de la ligne moyenne. L'erreur maximale est de 0.04.

Le résultat pour l'indice de santé MM est donné dans la Fig. 3.12. La référence reste toujours à l'intérieur de l'intervalle de confiance et l'erreur maximale de la ligne moyenne est petite : 0.025. Cette méthode est donc robuste aux perturbations et au bruit, elle est également bien adaptée à l'indice de santé multimodal, ou autrement dit aux différentes conditions opérationnelles.

### Analyse des résultats :

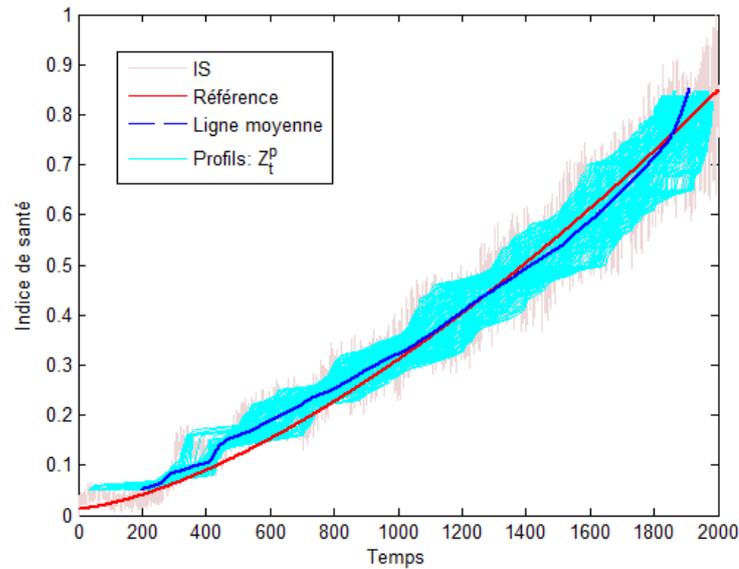


FIGURE 3.11 – L'application de la méthode des percentiles sur l'IS UM

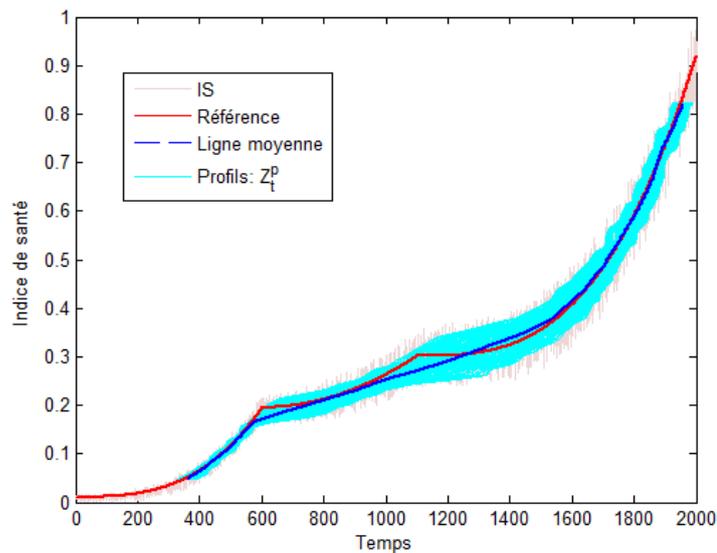


FIGURE 3.12 – L'application de la méthode des percentiles sur l'IS MM

La Table 3.3 présente une brève comparaison des méthodes de pré-traitement. Le critère du temps de calcul n'est pas donné dans cette table car il est de moins d'une seconde pour toutes les méthodes. Les erreurs d'estimation maximales sont respectivement données pour les indices de santé unimodal et multimodal. La méthode des percentiles donne l'erreur d'approximation la plus petite dans les deux cas. Parmi les méthodes présentées, seule la méthode des percentiles nous fournit un intervalle de confiance. Sur la forme de l'indice de santé, toutes les méthodes présentent des résultats satisfaisants.

	L'erreur maximale d'estimation	Intervalle de confiance	Unimodal, Multimodal	Complexité de la mise en place
Indices statistiques (RMS)	[0.07, 0.05]	Non	Les deux	Choix des indices, longueur de la fenêtre
DME Niveau 6 Niveau 7 Niveau 8	[0.04, 0.03] [0.04, 0.04] [0.06, 0.09]	Non	Les deux	Niveau de la décomposition
Filtre de passe-bas $w_c = 0.05$	[0.04, 0.05]	Non	Les deux	Choix de filtre, fréquence de coupure
DO Niveau 8 Niveau 9 Niveau 10	[0.03, 0.04] [0.05, 0.07] [0.08, 0.11]	Non	Les deux	Choix de la famille d'ondelette, Niveau
Méthode de percentile	[0.02, 0.03]	Oui	Les deux	Choix des percentiles

TABLE 3.3 – Synthèse de l'analyse comparative

Pour la complexité de la mise en place : les indices statistiques requièrent notamment un choix approprié des outils statistiques et le choix de la longueur de la fenêtre de calcul. Les décompositions en modes empiriques et en ondelettes nécessitent un choix du niveau de la décomposition qui dépend de la nature des données. L'utilisation de la décomposition en ondelettes nécessite également un choix de la famille d'ondelette qui n'est pas évident et dépend de la nature des données. De la même façon, les filtres de passe-bas requièrent un choix du filtre et de la fréquence de coupure qui sont dépendants des fréquences du bruit et des perturbations. La méthode des percentiles est simple à mettre en oeuvre et marche bien pour les deux indices de santé. Cependant, elle peut être améliorée pour d'autres domaines d'application par la quantification des informations conservées en fonction du choix des percentiles.

A partir de cette analyse, on constate que l'erreur d'estimation des méthodes DO, DME et la méthode des percentiles est faible. Néanmoins, la méthode des percentiles apparaît la meilleure pour le pré-traitement de l'indice de santé brut car elle donne l'erreur d'estimation la plus petite, elle préserve une grande partie de l'information utile, elle est applicable pour les indices de santé unimodaux et multimodaux, et sa mise en place ne

dépend que du choix des percentiles. Tandis que les méthodes DO et DME ne fournissent un bon résultat que dans le cas où on peut choisir un niveau adéquat de décomposition, une famille d'ondelettes appropriée (pour la DO) ou un critère d'arrêt en cohérence (pour la DME) avec les caractéristiques de l'IS. D'ailleurs, les figures 3.8 et 3.10 montrent que les profils obtenus par la DME et la DO contiennent des fluctuations. C'est à cause des perturbations sinusoidales et perturbations d'échelle que contient l'IS.

L'indice de santé caractérise l'état de santé actuel du système, mais pour estimer son temps de vie résiduel (RUL), il est nécessaire de modéliser son évolution future. Dans la section suivante, nous présentons les outils stochastiques de modélisation de l'indice de santé (choix issu de l'état de l'art détaillé dans le chapitre 1), puis nous proposons une méthode de modélisation qui tient compte de tous les profils générés par la méthode de percentiles.

## 3.2 Estimation du RUL des systèmes à un mode de fonctionnement (Méthode Gamma-percentiles)

Dans cette section, nous présentons une méthode de pronostic de défaillance des systèmes qui ont un seul point de fonctionnement, comme les équipements de fabrication de semi-conducteur qui réalisent la même tâche de façon répétitive. Ils sont donc soumis à la même consigne. La méthode développée combine le processus Gamma avec la méthode des percentiles, pour la prédiction du RUL à partir des profils extraits par la méthode des percentiles.

### 3.2.1 Modélisation

A partir de l'ensemble des  $m$  profils  $\{Z^p, p \in \{a, a+1, \dots, a+m-1\}\}$  extraits par la méthode des percentiles, chaque profil  $Z^p$  contient des temps d'inspection  $t_{i,p}, i \in \{1, \dots, n_p\}$  où  $0 \leq t_{1,p} < t_{2,p} < \dots < t_{n_p,p}$ , qui correspondent à la dégradation  $z_{i,p}, i \in \{1, \dots, n_p\}$  où  $0 \leq z_{1,p} \leq z_{2,p} \leq \dots \leq z_{n_p,p}$ .

Le processus Gamma est utilisé, avec le choix de la fonction de forme  $v(t) = ct^b$  et la paramètre d'échelle  $u$ . Les paramètres  $(\hat{u}, \hat{c}, \hat{b})$  du processus Gamma peuvent être estimés par la combinaison de la méthode des moindres carrés et la méthode des moments [65] comme suit. D'abord,  $\hat{b}$  est estimé par la méthode des moindres carrés :

$$\hat{b} = \frac{\sum_{p=a}^{a+m-1} \sum_{i=1}^{n_p} \log\left(\frac{t_{i,p}}{t_{n_p,p}}\right) \log\left(\frac{z_{i,p}}{z_{n_p,p}}\right)}{\sum_{p=a}^{a+m-1} \sum_{i=1}^{n_p} [\log\left(\frac{t_{i,p}}{t_{n_p,p}}\right)]^2} \quad (3.12)$$

Ensuite, les paramètres  $\hat{u}$  et  $\hat{c}$  sont estimés par la méthode des moments :

$$\frac{\hat{c}}{\hat{u}} = \frac{\sum_{p=a}^{a+m-1} z_{n_p,p}}{\sum_{p=a}^{a+m-1} t_{n_p,p}^{\hat{b}}} = \bar{\delta} \quad (3.13)$$

$$\frac{\sum_{p=a}^{a+m-1} z_{n_p,p}}{\hat{u}} \left(1 - \frac{\sum_{p=a}^{a+m-1} z_{n_p,p} \sum_{i=1}^{n_p} w_{i,p}^2}{\left[\sum_{p=a}^{a+m-1} z_{n_p,p} \sum_{i=1}^{n_p} w_{i,p}\right]^2}\right) = \sum_{p=a}^{a+m-1} \sum_{i=1}^{n_p} (\delta_{i,p} - \bar{\delta} w_{i,p}) \quad (3.14)$$

où  $w_{i,p} = t_{i,p}^{\hat{b}} - t_{i-1,p}^{\hat{b}}$ ,  $\delta_{i,p} = z_{i,p} - z_{i-1,p}$ .

### 3.2.2 L'estimation de temps de vie résiduel (RUL)

L'estimation du RUL se fait en ligne, à chaque acquisition à l'instant  $t$ , l'indice de santé est mis à jour, et un ensemble de  $m$  profils est extrait et noté  $\{Z^p, p \in \{a, a+1, \dots, a+m-1\}\}$ . Notons  $Z_\tau^p$  la valeur de  $Z^p$  à l'instant  $\tau$ . Pour chaque profil  $Z^p$ , la fonction de répartition du temps de défaillance  $\mathcal{T}_p$  avec le seuil de défaillance  $S_D$  est calculée comme

suit [50] :

$$\begin{aligned} F_p(t) &= Pr\{\mathcal{T}_p \leq t\} = Pr\{Z_t^p \geq S_D\} \\ &= \int_{y=S_D}^{\infty} f_{Z_t^p}(y) dy = \frac{\Gamma(\nu(t), S_D u)}{\Gamma(\nu(t))} \end{aligned} \quad (3.15)$$

où  $\Gamma(a, x) = \int_{z=x}^{\infty} z^{a-1} e^{-z} dz$ .

La valeur du RUL à l'instant  $t_{n,p}$  peut être définie comme le premier temps de passage de  $\{Z_t^p, t \geq t_{n,p}\}$  par  $S_D$ , cet instant est noté  $h_{t_{n,p}}$  et calculé comme suit :

$$h_{t_{n,p}} = \inf\{h_{t_{n,p}} : Z_{t_{n,p}+h_{t_{n,p}}}^p \geq S_D | Z_{t_{n,p}}^p < L\} \quad (3.16)$$

La fonction de répartition du RUL peut être écrite :

$$\begin{aligned} F_p(h_{t_{n,p}}) &= Pr\{Z_{t_{n,p}+h_{t_{n,p}}}^p \geq S_D\} \\ &= Pr\{Z_{t_{n,p}+h_{t_{n,p}}}^p - Z_{t_{n,p}}^p \geq S_D - z_{n,p}\} \\ &= \int_{y=S_D-z_{n,p}}^{\infty} Ga(\nu(h_{t_{n,p}} + t_{n,p}) - \nu(t_{n,p}), u) dy \\ &= \frac{\Gamma(\nu(h_{t_{n,p}} + t_{n,p}) - \nu(t_{n,p}), (S_D - z_{n,p})u)}{\Gamma(\nu(h_{t_{n,p}} + t_{n,p}) - \nu(t_{n,p}))} \end{aligned} \quad (3.17)$$

La fonction de densité de probabilité (fdp) du RUL du profil  $Z^p$  est :

$$\begin{aligned} f_{p,RUL}(h_{t_{n,p}}) &= \frac{\partial}{\partial h_{t_{n,p}}} \left[ \frac{\Gamma(\nu(h_{t_{n,p}} + t_{n,p}) - \nu(t_{n,p}), (S_D - z_{n,p})u)}{\Gamma(\nu(h_{t_{n,p}} + t_{n,p}) - \nu(t_{n,p}))} \right] \end{aligned} \quad (3.18)$$

La fdp du temps de défaillance  $\mathcal{T}_p$  du profil  $Z^p$  est :

$$f(\mathcal{T}_p) = f_{p,RUL}(\mathcal{T}_p - t_{n,p}) \quad (3.19)$$

$$f(\mathcal{T}_p) = \frac{\partial}{\partial (\mathcal{T}_p - t_{n,p})} \left[ \frac{\Gamma(\nu(\mathcal{T}_p) - \nu(t_{n,p}), (S_D - z_{n,p})u)}{\Gamma(\nu(\mathcal{T}_p) - \nu(t_{n,p}))} \right] \quad (3.20)$$

La moyenne des fdp calculées ci-dessus est une fdp qui est plus étendue et permet de tenir en compte la densité de probabilité de l'ensemble des distributions obtenues. Cela est illustré dans la Fig. 3.13 où la fdp en pointillés noirs est la moyenne des autres fdp étant la fdp des profils différents. Ainsi, l'estimation du RUL est réalisée en synthétisant une fdp agrégée du temps de défaillance des  $m$  profils au lieu d'utiliser la fdp d'un seul profil. Ainsi, la fdp agrégée du temps de défaillance  $f(\mathcal{T})$  synthétisée à partir des  $m$  profils  $\{Z^p, p \in \{a, a+1, \dots, a+m-1\}\}$  est proposée dans l'équation 3.21 :

$$f(\mathcal{T}) = \frac{1}{m} \sum_{p=a}^{a+m-1} f(\mathcal{T}_p) \quad (3.21)$$

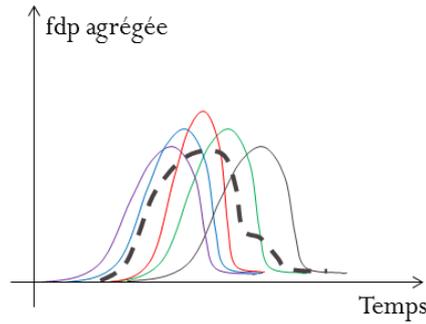


FIGURE 3.13 – Illustration de la moyenne des fdp individuelles

La fdp agrégée du RUL est donc :

$$f_{RUL}(h_t) = f(t + h_t) \quad (3.22)$$

Le choix d'utilisation d'une moyenne pour obtenir la fdp du temps de défaillance à partir de celles des temps d'atteinte des seuils par les profils monotones simplifie le calcul, et donc la mise en oeuvre de la méthode. L'incertitude induite par ce choix est couverte par le calcul d'un intervalle de confiance (*IC*).

La limite inférieure  $IC_{LI,90\%}$  et la limite supérieure  $IC_{LS,90\%}$  de l'intervalle de confiance du RUL peuvent être calculées comme suit :

$$\int_0^{CI_{LI,90}} f_{RUL}(h_t)d(h_t) = 0.05 \quad (3.23)$$

$$\int_0^{CI_{LS,90}} f_{RUL}(h_t)d(h_t) = 0.95 \quad (3.24)$$

Le RUL moyen estimé est :

$$E(h_t) = \int_{h_t=0}^{\infty} h_t f_{RUL}(h_t)d(h_t) \quad (3.25)$$

### 3.2.3 Exemple d'illustration

Cette partie présente un exemple de la prédiction du RUL par le processus de Wiener mis-à-jour, le processus Gamma et la combinaison du processus Gamma et la méthode des percentiles. Le pré-traitement présenté ci-dessus fournit les profils extraits pour l'utilisation des méthodes : le processus de Wiener et le processus Gamma sont appliqués sur les profils extraits par les technique Décomposition en modes empiriques  $Z^{DME}$  et Décomposition en ondelettes  $Z^{DO}$  ; tandis que la méthode Gamma-percentiles est appliqué sur les profils  $\{Z^p\}$  extraits par la méthode des percentiles. Le seuil du fonctionnement normal est choisi  $S_N = 0.05$  et le seuil de la défaillance est choisi  $S_D = 0.85$  comme illustré dans la Fig. 3.14.

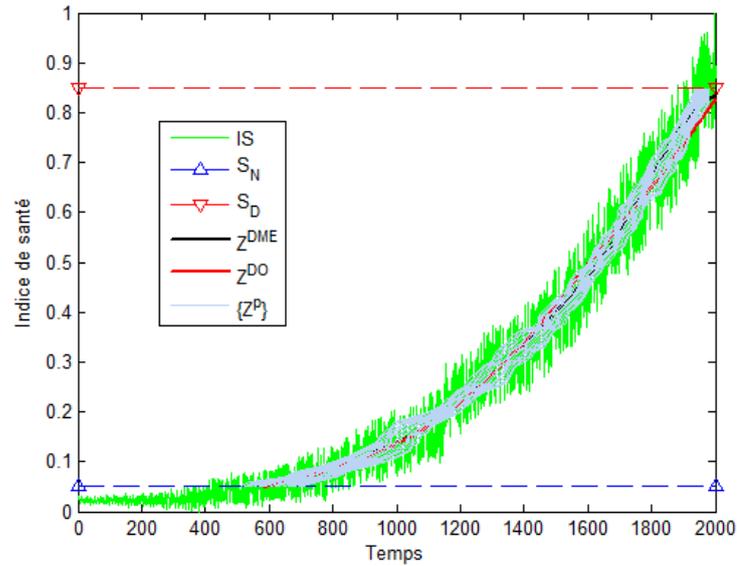


FIGURE 3.14 – L'indice de santé et les seuils

### 3.2.3.1 Processus de Wiener

Le processus de Wiener mis-à-jour est appliqué sur les profils  $Z^{DME}$  et  $Z^{DO}$  de la Fig. 3.14. Le paramètre  $\hat{\mu}_t$  varie significativement dans le temps, comme montré dans la Fig. 3.15. Cela est explicable par le fait que les profils extraits par les techniques existantes comme DME et DO ne suivent pas la tendance de l'IS sur quelques périodes de temps à cause de la présence des perturbations (montré dans la comparaison des méthodes de pré-traitement auparavant).

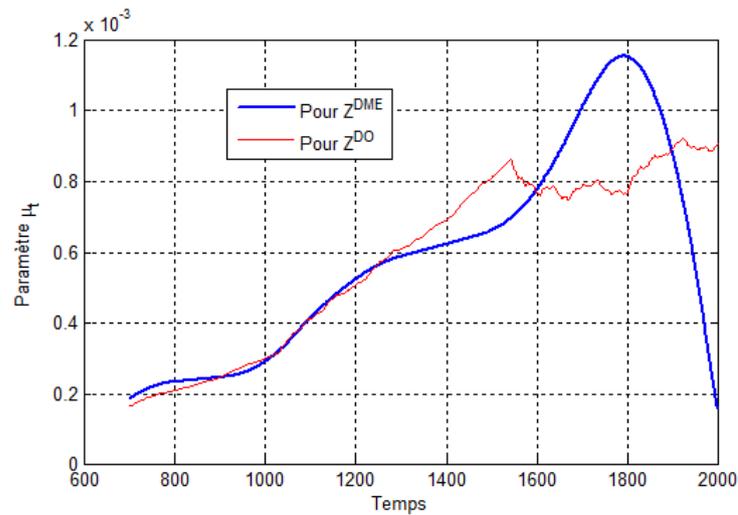


FIGURE 3.15 – Le paramètre  $\hat{\mu}_t$  estimé

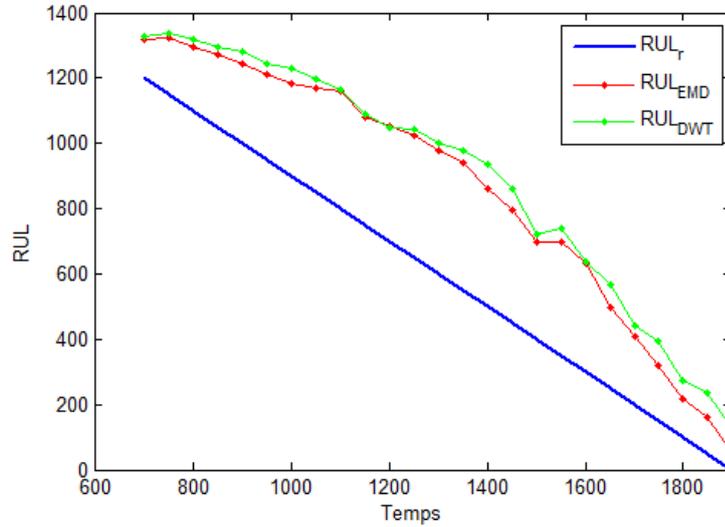


FIGURE 3.16 – Le RUL estimé par le processus de Wiener conventionnel

Avec ce profil de  $\hat{\mu}_t$  il est évident que l'estimation du RUL sera mauvaise, nous avons donc opté pour l'application du processus de Wiener conventionnel sur les deux profils  $Z^{DME}$  et  $Z^{DO}$  au lieu du processus Wiener mis à jour. Les paramètres estimés  $[\hat{\mu}, \hat{\sigma}]$  sont respectivement :  $[5.9 \times 10^{-4}, 2.9 \times 10^{-4}]$  et  $[5.9 \times 10^{-4}, 2.5 \times 10^{-4}]$ . Le résultat du RUL estimé est donné dans la Fig. 3.16. L'erreur moyenne quadratique de la prédiction est grande : 280 pour le profil extrait par la technique DME et 312.8 pour le profil extrait par la technique DO.

### 3.2.3.2 Processus Gamma

Pour la modélisation par le processus Gamma sur les profils  $Z^{DME}$  et  $Z^{DO}$ , les paramètres estimés sont :  $\hat{u} = 2.13 \times 10^4$ ,  $\hat{c} = 7.66 \times 10^{-5}$  et  $\hat{b} = 2.53$  pour  $Z^{DME}$  ;  $\hat{u} = 1.16 \times 10^5$ ,  $\hat{c} = 4.26 \times 10^{-4}$  et  $\hat{b} = 2.53$  pour  $Z^{DO}$ .

Pour les données de test, le temps de défaillance est connu et égale à 1900. Le RUL réel à l'instant  $t$  est donc  $RUL_r = 1900 - t$ . Le RUL estimé est noté  $RUL_e$ . Les RUL estimés pour les deux cas  $Z^{DME}$  et  $Z^{DO}$  sont donnés respectivement dans les figures 3.17 et 3.18. Les erreurs moyennes quadratiques sont respectivement : 106.3 et 125.33. On constate que la prédiction du RUL par le processus Gamma est meilleure que celle utilisant le processus de Wiener. Cependant, le RUL estimé ne reste pas dans l'intervalle des 20% du RUL réel.

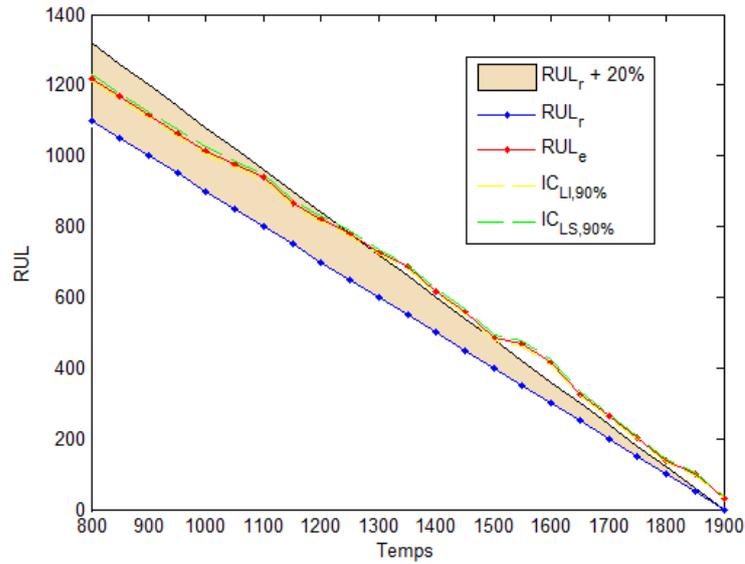


FIGURE 3.17 – Le RUL estimé par le processus Gamma avec le profil extrait par la DME

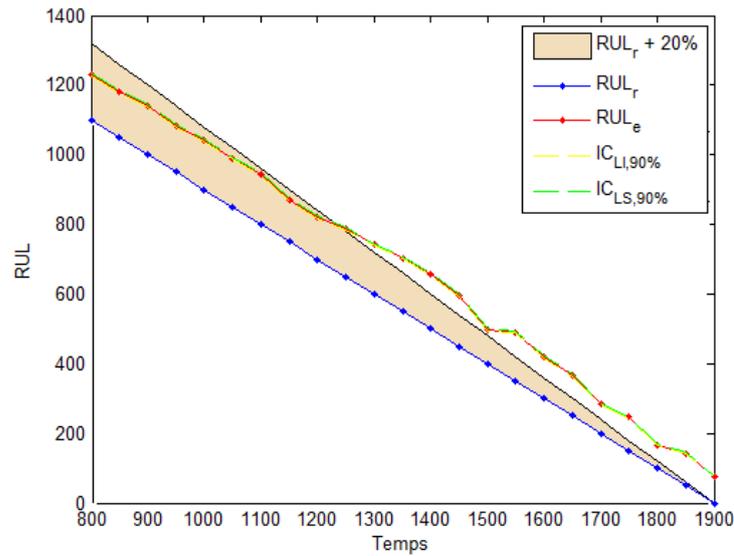


FIGURE 3.18 – Le RUL estimé par le processus Gamma avec le profil extrait par la DO

### 3.2.3.3 Méthode Gamma-percentiles

Pour cette méthode, les paramètres de la modélisation par le processus Gamma sont obtenus :  $[\hat{u}, \hat{c}, \hat{b}] = [415.80, 6.7 \times 10^{-7}, 2.65]$ .

Pour illustrer le calcul de la fonction de densité de probabilité (fdp) agrégée du temps de défaillance,  $f(\mathcal{T}_p)_p$  et  $f(\mathcal{T})$  à l'instant  $t = 1000$  sont respectivement calculées et illustrées dans les figures 3.19 et 3.20.

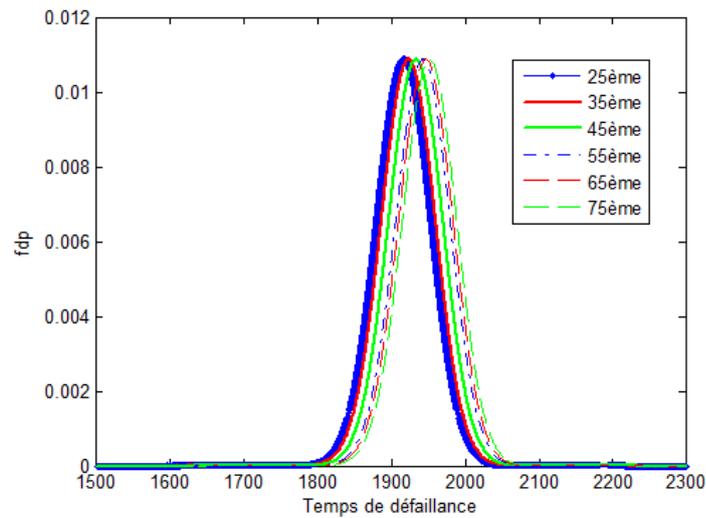


FIGURE 3.19 – Illustration de la fdp du temps de défaillance pour chaque percentile

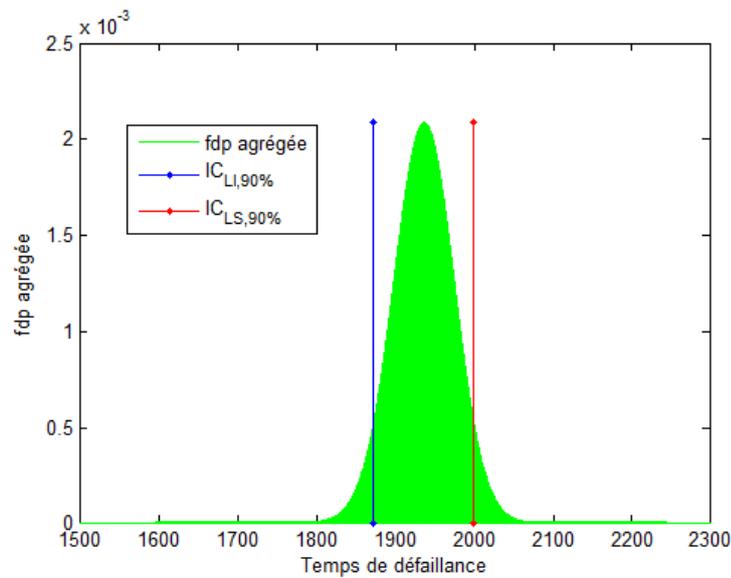


FIGURE 3.20 – Illustration de la fdp agrégée du temps de défaillance

	Proc. de Wiener	Proc. Gamma	Gamma-percentiles
Erreur moyenne	280.9 avec DME	106.3 avec DME	55.9
quadratique	312.8 avec DO	125.33 avec DO	

TABLE 3.4 – Comparaison des erreurs de prédiction des méthodes

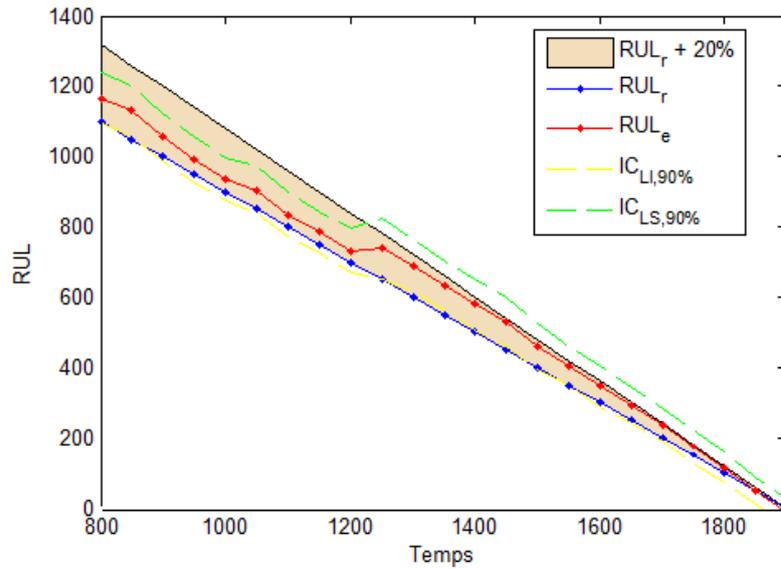


FIGURE 3.21 – La méthode Gamma-percentiles : Le RUL estimé comparé au RUL réel

La comparaison entre le RUL estimé et le RUL réel est donnée dans la Fig. 3.21. La distance entre la limite inférieure et la limite supérieure est grande car cette méthode prend en compte plusieurs profils extraits d'un indice de santé bruité. Mais le résultat montre que l'erreur de la prédiction du RUL est inférieure à 20% de la valeur réelle du RUL, l'erreur quadratique du RUL estimé est de 55.90. La table 3.4 compare les erreurs moyennes quadratiques de la prédiction du RUL, elle montre que la méthode Gamma-percentiles donne le résultat le plus exact parmi les méthodes présentées.

### 3.3 Estimation du RUL des systèmes à multi-modes de fonctionnement (Modèle IS à multi-modes)

Cette section est dédiée au pronostic de défaillance des systèmes qui ont plusieurs points de fonctionnement, par exemple les équipements de fabrication du semi-conducteur qui traitent des produits de différentes technologies. Ils sont donc soumis à des variations de consigne en fonction de la tâche à accomplir.

Dans la pratique, il y a des machines sur lesquelles plusieurs modes de fonctionnement sont exécutés. Les différents modes de fonctionnement causent différents taux de dégradation, autrement dit, ils provoquent différentes dynamiques de la dégradation. Un changement des caractéristiques de l'environnement dans laquelle le système est mis en fonctionnement peut également causer un changement de la dynamique de la dégradation. Les caractéristiques des modes de fonctionnement ou de l'environnement peuvent être présentées par des covariables. Les processus de Wiener et les processus Gamma classiques ne permettent ni d'incorporer ces variables dans la modélisation ni de décrire un tel phénomène.

Cox [71] a proposé un modèle qui permet de modéliser le risque de défaillance en considérant la relation entre ce risque et les covariables, mais pas de modéliser un indice de santé. [51] et [63] ont proposé d'incorporer les covariables dans la fonction de forme ou dans le paramètre d'échelle du processus Gamma. Une étude de la fiabilité en fonction de la dégradation et les covariables est donnée dans [52].

Dans cette section, un nouveau modèle de l'IS d'un système à fonctionnement multi-modes est développé et illustré dans la Fig.3.22. La forme du taux de défaillance proposée par Cox est reprise dans ce modèle pour décrire des incréments de cet IS, cela permet de considérer les incréments comme une multiplication entre une fonction exponentielle du facteur des covariables et une fonction du temps. La méthode est présentée en deux parties : la modélisation de la dégradation dans la section 3.3.1 et l'estimation du RUL dans la section 3.3.2.

#### 3.3.1 Modélisation de l'indice de santé

Ce modèle se base sur deux hypothèses : (1) la valeur future de l'IS est une fonction de l'état actuel du système donné par la valeur actuelle de l'IS, le temps, les modes d'utilisation supposés connus et les bruits extérieurs qui sont supposés suivre une loi gaussienne ; (2) l'IS est non-négatif et monotone.

Compte-tenu de ces deux hypothèses, la dynamique de l'IS peut être décrite par l'équation 3.26 :

$$\Delta X_t = \frac{\beta t^{\beta-1}}{\eta^\beta} \exp(\gamma Z_t + \varepsilon) \quad (3.26)$$

où  $\beta > 0$ ,  $\eta > 0$ ,  $\gamma = [\gamma_1, \dots, \gamma_m] \in \mathbb{R}^m$  est un vecteur de  $m$  éléments, qui décrivent

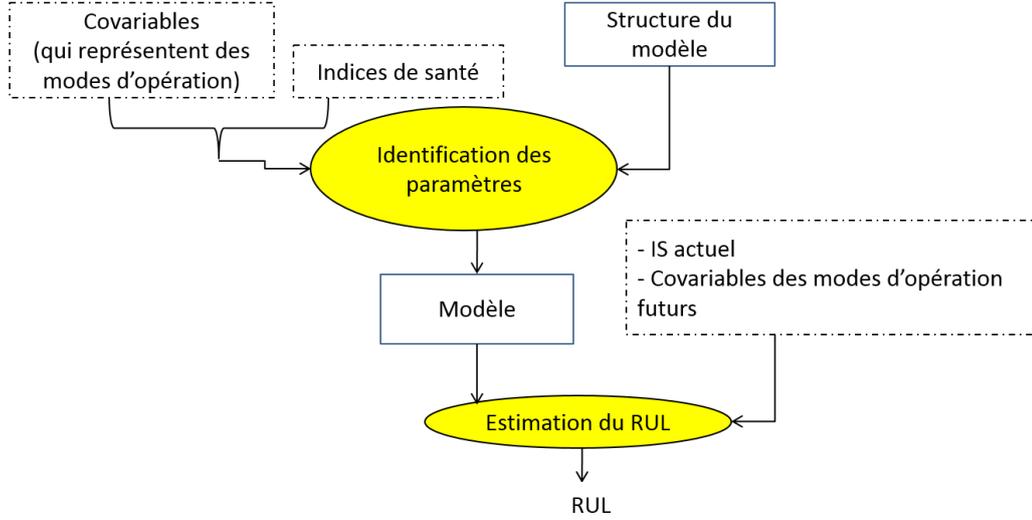


FIGURE 3.22 – Diagramme de la modélisation de la dégradation et l'estimation du RUL

l'influence des changements de modes de fonctionnement  $Z_t = [Z_{1,t}, \dots, Z_{m,t}]$  sur la dégradation. Les incertitudes du modèle sont représentées par la variable  $\varepsilon$  qui est supposée suivre une distribution normale  $N(0, Q)$ . Le premier terme  $\beta t^{\beta-1}/\eta^\beta$  dépend du temps, cela signifie que  $\Delta X_t$  dépend de l'âge du système.

Dans le cas où la dégradation est indépendante des modes de fonctionnement, le vecteur  $\gamma$  égale à zéro, ainsi :

$$\Delta X_t = \frac{\beta t^{\beta-1}}{\eta^\beta} \exp(\varepsilon) \quad (3.27)$$

Puisque l'IS  $X_t$  est monotone, il est défini comme l'accumulation de tous les segments  $\Delta X_t$  :

$$X_t = \sum_{\tau=0}^t \Delta X_\tau \quad (3.28)$$

En se basant sur la linéarité de l'espérance mathématique, la valeur de l'espérance mathématique de  $X(t)$  est calculée comme suit :

$$\begin{aligned} E[X_t] &= E\left[\sum_{\tau=0}^t \Delta X_\tau\right] \\ &= \sum_{\tau=0}^t E[\Delta X_\tau] \\ &= \sum_{\tau=0}^t E\left[\frac{\beta \tau^{\beta-1}}{\eta^\beta} \exp(\varepsilon)\right] \\ &= \sum_{\tau=0}^t \frac{\beta \tau^{\beta-1}}{\eta^\beta} E[\exp(\varepsilon)] \end{aligned} \quad (3.29)$$

$\epsilon \sim N(0, Q)$  étant une variable de distribution normale,  $\exp(\epsilon)$  est donc une variable de distribution log-normale, sa valeur moyenne est  $\exp(Q/2)$ .

$$\begin{aligned} E[X_t] &= \sum_{\tau=0}^t \frac{\beta \tau^{\beta-1}}{\eta^\beta} \exp(Q/2) \\ &= \exp(Q/2) \sum_{\tau=0}^t \frac{\beta \tau^{\beta-1}}{\eta^\beta} \end{aligned} \quad (3.30)$$

Comme

$$(t+1)^\beta - t^\beta = \beta t^{\beta-1} + O(t^{\beta-1}) \approx \beta t^{\beta-1} \quad (3.31)$$

$$(t+1)^\beta - t^\beta = \int_t^{t+1} \beta u^{\beta-1} du \quad (3.32)$$

donc :

$$\beta t^{\beta-1} \approx \int_t^{t+1} \beta u^{\beta-1} du \quad (3.33)$$

$$\beta \tau^{\beta-1} / (\eta^\beta) \approx \int_\tau^{\tau+1} \beta u^{\beta-1} / (\eta^\beta) du \quad (3.34)$$

$E[X_t]$  peut être estimée comme suit :

$$\begin{aligned} E[X_t] &= \exp(Q/2) \sum_{\tau=0}^t \frac{\beta \tau^{\beta-1}}{\eta^\beta} \\ &\approx \exp(Q/2) \int_0^t \frac{\beta u^{\beta-1}}{\eta^\beta} du \\ &= \exp(Q/2) \frac{t^\beta}{\eta^\beta} \\ &= \frac{ct^b}{u} \end{aligned} \quad (3.35)$$

avec  $c = \exp(Q/2)$ ,  $b = \beta$ ,  $u = \eta^\beta$ .  $E[X_t]$  est l'espérance de l'IS modélisée par le processus Gamma dont le paramètre de forme suit une loi de puissance  $v(t) = ct^b$  et le paramètre d'échelle  $u$  est constant.

### Identification des paramètres

Notons  $h_t = \beta t^{\beta-1} / \eta^\beta$ . L'équation (3.26) peut être réécrite comme suit :

$$\log(\Delta X_t) = \log(h_t) + \gamma Z_t + \epsilon \quad (3.36)$$

Ainsi, la fonction de densité de probabilité (*fdp*) de  $\Delta X_t$  et  $Z_t$  étant donnés les paramètres  $(\beta, \eta, \gamma, Q)$  peut s'écrire :

$$\begin{aligned} &fdp(\log(\Delta X_t), Z_t | \beta, \eta, \gamma, Q) \\ &= \frac{1}{\sqrt{2\pi Q}} \exp\left(-\frac{(\log(\Delta X_t) - \log(h_t) - \gamma Z_t)^2}{2Q}\right) \end{aligned} \quad (3.37)$$

Pour un ensemble de données de  $N$  expériences, notons l'IS et les covariables respectivement  $X_{j,t}$  et  $Z_{j,t}$ ,  $j \in \{1, \dots, N\}$ ,  $t \in \{1, \dots, T_j\}$  avec  $T_j$  la dernière observation sur la covariable  $j$ , la fonction de vraisemblance de cet ensemble de données est :

$$L = \prod_{j=1}^N \prod_{t=1}^{T_j} \frac{1}{\sqrt{2\pi Q}} \exp\left(-\frac{(\log(\Delta X_{j,t}) - \log(h_t) - \gamma Z_{j,t})^2}{2Q}\right) \quad (3.38)$$

Les paramètres sont estimés par la technique de l'estimation du maximum de vraisemblance (EMV). Maximiser la fonction de vraisemblance est équivalent à maximiser sa fonction log, écrite comme suit :

$$\begin{aligned} \varphi &= \log(L) \\ &= -\frac{\log(2\pi) + \log(Q)}{2} \left( \sum_{j=1}^N T_j \right) \\ &\quad - \sum_{j=1}^N \sum_{t=1}^{T_j} \frac{(\log(\Delta X_{j,t}) - \log(h_t) - \gamma Z_{j,t})^2}{2Q} \end{aligned} \quad (3.39)$$

avec  $\log(h_t) = \log(\beta) + (\beta - 1)\log(t) - \beta\log(\eta)$ . La fonction  $\varphi$  est maximum lorsque  $\delta\varphi/\delta x = 0$  et  $\delta^2\varphi/\delta x^2 < 0$  avec  $x \in \{\beta, \eta, \gamma_{s,s=1,\dots,m}, Q\}$ .

Une fois que les paramètres sont identifiés, le RUL est calculé en se basant sur les modes de fonctionnement futurs issus du plan de production ainsi que sur la dégradation actuelle.

### 3.3.2 Estimation du RUL

$X_t$  est la valeur de l'IS à l'instant  $t$ . Supposons  $k$  le RUL et  $L > X_t$  le seuil prédéfini de défaillance.

$$P(k|X_t < L) = P(X_{t+k} < L|X_t < L) \quad (3.40)$$

$$= P\left(X_t + \sum_{i=t+1}^{t+k} \Delta X_i < L\right) \quad (3.41)$$

$$= P\left(\sum_{i=t+1}^{t+k} \Delta X_i < L - X_t\right) \quad (3.42)$$

$$= F_{\sum_{i=t+1}^{t+k} \Delta X_i}(L - X_t) \quad (3.43)$$

où  $F_{\sum_{i=t+1}^{t+k} \Delta X_i}(L - X_t)$  est la fonction de répartition de la somme  $S_k = \sum_{i=t+1}^{t+k} \Delta X_i$  à la valeur  $L - X_t$ .

A partir de l'équation (3.36),  $\log(\Delta X_i)$  peut être réécrit :

$$\log(\Delta X_i) \sim N(\mu_i, \sigma^2) \quad (3.44)$$

qui est une variable de distribution normale avec

$\mu_i = \left( \log(\beta) + (\beta - 1)\log(i) - \beta\log(\eta) \right) + \gamma Z_i$ ,  $\sigma^2 = Q$ . Ainsi,  $\Delta X_i$  suit une distribution Log-Normale :

$$\Delta X_i \sim \text{log-normal}(\mu_i, \sigma^2) \quad (3.45)$$

Supposons que les segments  $\Delta X_i, i \in \{t + 1, \dots, t + k\}$  sont indépendants les uns des autres. Comme chaque variable  $\Delta X_i$  est une variable de distribution Log-Normale, la somme  $S_k$  est également une variable de distribution Log-Normale selon l'approximation de Fenton-Wilkinson [153] :

$$S_k \sim \text{log-normal}(\mu_{\Sigma_k}, \sigma_{\Sigma_k}^2) \quad (3.46)$$

La valeur moyenne  $\mathcal{M}_k = E[S_k]$  et la variance  $\mathcal{V}_k = VAR[S_k]$  sont :

$$\begin{aligned} \mathcal{M}_k &= E[S_k] = e^{\mu_{\Sigma_k} + \sigma_{\Sigma_k}^2/2} \\ &= \sum_{i=t+1}^{t+k} E[\Delta X_i] = \sum_{i=t+1}^{t+k} e^{\mu_i + \sigma^2/2} \end{aligned} \quad (3.47)$$

Puisque les  $\Delta X_i$  sont supposés indépendants les uns des autres, alors :

$$\begin{aligned} \mathcal{V}_k &= VAR[S_k] = e^{2\mu_{\Sigma_k} + \sigma_{\Sigma_k}^2} (e^{\sigma_{\Sigma_k}^2} - 1) \\ &= \sum_{i=t+1}^{t+k} VAR[\Delta X_i] = \sum_{i=t+1}^{t+k} e^{2\mu_i + \sigma^2} (e^{\sigma^2} - 1) \end{aligned} \quad (3.48)$$

Les deux termes  $\mu_{\Sigma_k}$  et  $\sigma_{\Sigma_k}^2$  sont calculés à partir de  $\mathcal{M}_k$  et  $\mathcal{V}_k$  comme suit [153] :

$$\mu_{\Sigma_k} = \log(\mathcal{M}_k) - \frac{\sigma_{\Sigma_k}^2}{2} \quad (3.49)$$

$$\sigma_{\Sigma_k}^2 = \log\left(1 + \frac{\mathcal{V}_k}{\mathcal{M}_k^2}\right) \quad (3.50)$$

Ainsi, la fonction de répartition de la somme  $S_k = \sum_{i=t+1}^{t+k} \Delta X_i$  à la valeur  $L - X_t$  est :

$$P(k|X_t < L) = F_{S_k}(L - X_t) \quad (3.51)$$

$$= \text{log-normal}(L - X_t | \mu_{\Sigma_k}, \sigma_{\Sigma_k}^2) \quad (3.52)$$

La fdp du RUL est donc :

$$f(k) = \frac{\delta}{\delta k} F_{\sum_{i=t+1}^{t+k} \Delta X_i}(L - X_t) \quad (3.53)$$

L'espérance du RUL à l'instant  $t$ , notée  $\mathcal{R}_t$  est calculée comme suit :

$$\mathcal{R}_t = E[k] = \int_0^{\infty} k f(k) dk \quad (3.54)$$

### 3.3.3 Exemple d'illustration

La méthode est appliquée sur un ensemble de données de simulation détaillé ci-dessous. Pour implémenter ce modèle, deux ensembles d'entrées sont demandés (Fig. 3.22) : des covariables de consigne qui représentent les conditions opérationnelles et les indices de santé correspondants, puis la sortie est le RUL estimé. Dans cette application, il y a deux covariables ( $Z_1, Z_2$ ) comme illustré dans la Fig. 3.23. Les deux figures montrent respectivement les données des covariables pour l'indice de santé  $X_1$  et  $X_2$ . Il y a cinq modes correspondants aux cinq ensembles de valeurs de  $(Z_1, Z_2)$  suivants :  $(1, 2)$ ,  $(0, 2)$ ,  $(-1, 1)$ ,  $(2, 1)$  et  $(1, 1)$ . Les paramètres  $(\beta, \eta, \gamma, Q)$  sont donnés dans la Table 3.5. Les indices de santé correspondants sont donnés dans la Fig. 3.24, ils montrent le changement de la vitesse de la dégradation selon le changement de modes.

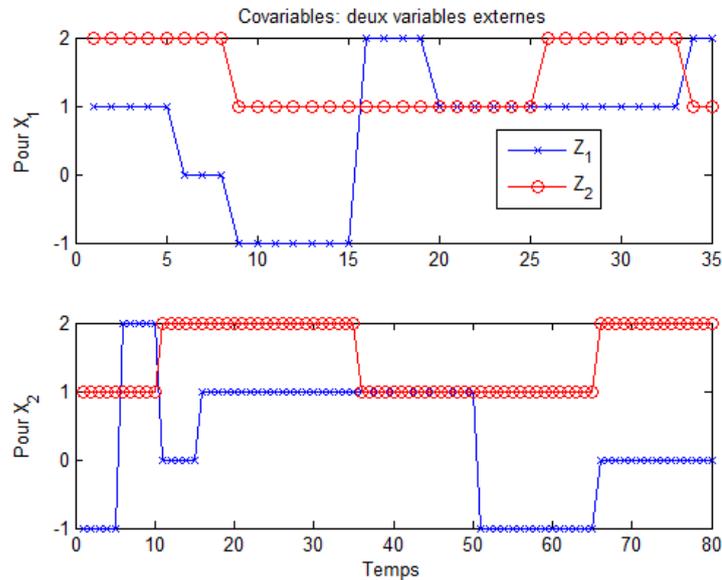


FIGURE 3.23 – Deux covariables qui représentent cinq modes de condition opérationnelle

	Paramètres
$\beta$	1.5
$\eta$	3
$\gamma$	$[-3/4 \quad 1/4]$
$Q$	$3/5$

TABLE 3.5 – Des paramètres choisis

Afin de vérifier l'efficacité du modèle développé, deux scénarios sont proposés. Le premier scénario *S.I* consiste à considérer les données d'apprentissage contenant la totalité de données de l'indice  $X_1$  et la valeur correspondante des covariables. Il représente la situation où la totalité des données sont disponibles, du fonctionnement normal jusqu'à

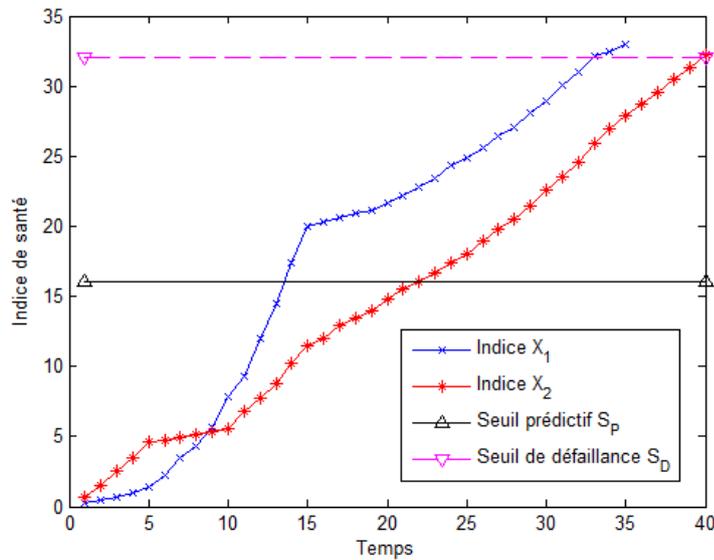


FIGURE 3.24 – Les indices de santé correspondants

la défaillance. L'indice de santé  $X_2$  et les valeurs correspondantes des covariables sont utilisés comme données de test.

Le deuxième scénario *S.II* consiste à considérer une partie des données des indices de santé, allant du fonctionnement normal jusqu'à un seuil prédictif  $S_P$  et la valeur correspondante des covariables comme les données d'apprentissage. Ce scénario est relié au cas où les données décrivant l'historique de la défaillance ne sont pas complètes. La notion *seuil prédictif* suppose que la modélisation de la défaillance et l'estimation du temps de vie résiduel peuvent être réalisées avec suffisamment d'exactitude lorsque l'indice de santé atteint ce seuil. La définition et le calcul du seuil prédictif  $S_P$  est en dehors de ce travail. Supposant que dans cette application,  $S_P = 16$ , ce qui correspond à la moitié de la valeur du seuil de défaillance  $S_D = 32$ . Alors, les données d'apprentissage contiennent les valeurs des variables et des deux indices de santé, de l'instant  $t = 0$  à l'instant  $t = 14$  pour  $X_1$  et de l'instant  $t = 0$  à l'instant  $t = 21$  pour  $X_2$ . Les données de test sont le reste des valeurs de  $X_2$  et les valeurs correspondantes des variables de consigne. Dans cet exemple, un bruit  $\epsilon \sim N(0, 3/5)$  est introduit dans les données

L'estimation du RUL est basée sur les modes planifiés connus. La Fig. 3.24 montre que le temps de défaillance de  $X_2$  est  $t = 41$ . La comparaison entre le RUL estimé et le RUL réel pour les deux scénarios est donnée dans les Fig. 3.25 et Fig. 3.26 respectivement. La Fig. 3.24 montre le RUL estimé pour le scénario S.I de l'instant  $t = 5$  à l'instant  $t = 40$ . Le RUL estimé est proche du RUL réel et reste dans l'intervalle des 90% du RUL réel.

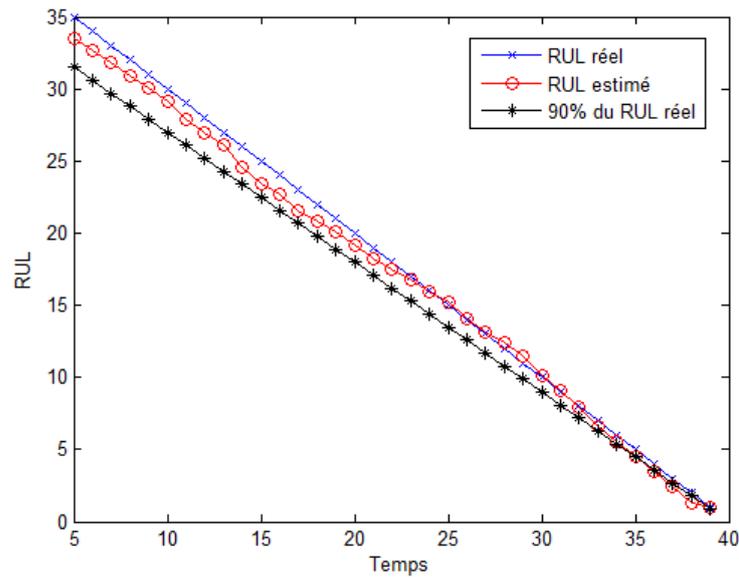


FIGURE 3.25 – La comparaison du RUL estimé et du RUL réel pour le scénario S.I

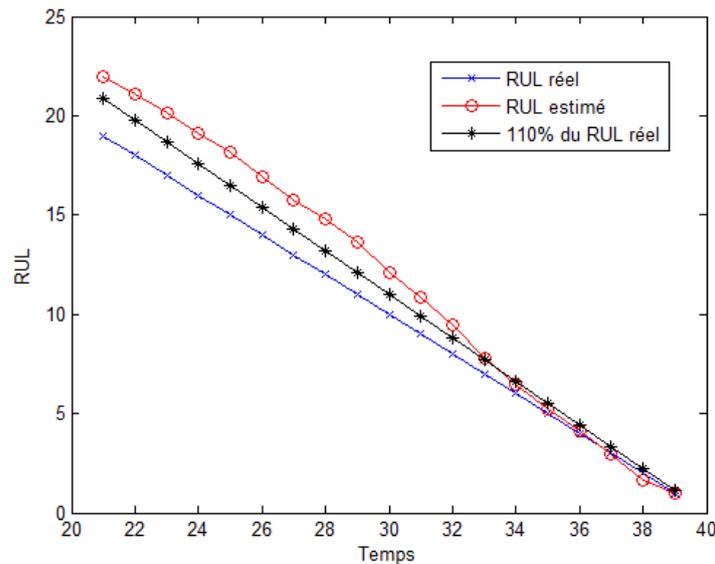


FIGURE 3.26 – La comparaison du RUL estimé et du RUL réel pour le scénario S.II

La Fig. 3.26 montre le RUL estimé comparé au RUL réel pour le scénario S.II de l'instant  $t = 21$  (juste après l'atteinte du seuil prédictif) à l'instant  $t = 40$ . Avant l'instant  $t = 33$ , le RUL estimé est en dehors de l'intervalle des 110% du RUL réel ; mais ensuite, il reste principalement dans cet intervalle jusqu'à la défaillance. Ce résultat montre que plus l'historique des données est important plus l'estimation est meilleure.

La Table 3.6 présente la comparaison des résultats obtenus avec les deux scénarios. Elle montre que dans le cas où les données de dégradation ne sont pas complètes, l'estimation

	Paramètres choisis	Estimation avec le scenario S.I	Estimation avec le scenario S.II
$\beta$	1.5	1.36	1.41
$\eta$	3	3.18	2.99
$\gamma$	$[-3/4 \quad 1/4]$	$[-0.45 \quad 0.19]$	$[-0.80 \quad 0.15]$
$Q$	3/5	0.055	0.042
L'erreur absolue maximale du RUL estimé		1.4	3.2
L'erreur du $\in 10\%$ RUL estimé		Principalement Oui	Principalement Non

TABLE 3.6 – La comparaison du résultat des deux scenarios

du RUL est moins exacte. Lorsque les données décrivant la dégradation sont complètes, l'estimation du RUL est plus exacte. La comparaison montre également que l'exactitude de la méthode développée est plus sensible à l'exactitude de l'estimation du vecteur  $\gamma$  qu'à l'exactitude de l'estimation des autres paramètres. L'erreur du RUL estimé dans les deux scénarios est raisonnable.

## 3.4 Conclusion

Dans ce chapitre, nous avons présenté une méthode d'estimation du temps de vie résiduel (RUL) lorsque l'indice de santé brut est disponible, il comporte trois contributions principales :

La première contribution concerne la méthode des percentiles qui extrait des profils monotones à différents niveaux de percentile. Cela permet donc de prendre en compte la variabilité des données et la marge de sécurité de la prédiction du RUL. Elle réduit la perte des informations tandis que les techniques de pré-traitement existantes temporelles ou fréquentielles ne permettent d'extraire qu'un seul profil à partir de l'indice de santé brut. Une comparaison de la méthode des percentiles et les techniques existantes est donnée en s'appuyant sur un exemple d'illustration, cela montre que la méthode développée est la plus robuste aux bruits et perturbations.

Deuxièmement, le RUL est ensuite estimé par une méthode originale : c'est une combinaison du processus Gamma et la méthode des percentiles. La méthode proposée permet de calculer la fonction de densité de probabilité (fdp) agrégée du temps de défaillance à partir de la fdp du temps de défaillance de chaque profil. L'exemple d'illustration montre que l'erreur du RUL estimé par cette méthode est significativement plus petite que l'erreur du RUL estimé par les processus de Wiener et processus Gamma conventionnels associés aux prétraitements différents.

Troisièmement, ce chapitre développe un modèle pour la prédiction du RUL quand la condition opérationnelle du système est multimodale. Ce modèle est appelé *Indice de Santé à multi-modes* et bien adapté au pronostic en-ligne.

Le chapitre suivant présente l'application de l'approche de pronostic développée dans ce manuscrit (Fig. 1.9) avec tout ces modules, génération de l'IS à partir du tenseur de données, pré-traitement de l'indice pour générer des profils monotones, et modélisation des profils pour l'estimation du RUL dans un intervalle de confiance.



# 4

## Application industrielle

### Sommaire

---

<b>4.1</b>	<b>Introduction</b>	<b>92</b>
<b>4.2</b>	<b>Application 1 : Description de l'équipement</b>	<b>93</b>
<b>4.3</b>	<b>Génération de l'indice de santé</b>	<b>94</b>
4.3.1	Méthode RD-ACP	94
4.3.2	Méthode RD-ACPM	97
4.3.3	Méthode PS-ACP	98
4.3.4	Analyse des résultats	99
<b>4.4</b>	<b>Pronostic de défaillance</b>	<b>101</b>
4.4.1	Pré-traitement de l'indice de santé brut	101
4.4.2	Modélisation de l'indice de santé et Estimation du RUL	103
4.4.2.1	Pronostic de défaillance pour S.I	103
4.4.2.2	Pronostic de défaillance pour scénario S.II	108
<b>4.5</b>	<b>Application 2</b>	<b>109</b>
<b>4.6</b>	<b>Conclusion</b>	<b>114</b>
4.6.1	Applications considérées	114
4.6.2	Perspective d'implémentation dans le milieu industriel	115

---

## 4.1 Introduction

Ce chapitre présente l'application de l'approche de pronostic de défaillance développée dans ce manuscrit sur deux équipements industriels de fabrication de semi-conducteur. Après une description détaillée des données réelles utilisées dans ce chapitre (section 4.2), le résultat de l'application de la méthode d'extraction de l'indice de santé brut à partir du tenseur de données est présentée dans la section 4.3. La prédiction du RUL est présentée dans la section 4.4 en commençant par le pré-traitement par la méthode des percentiles, puis l'estimation des paramètres du processus Gamma et le calcul de la fdp agrégée. Dans la dernière partie les résultats de l'estimation du RUL et l'intervalle de confiance généré sont donnés puis discutés pour illustrer l'efficacité de l'approche proposée.

### Cadre de l'application

L'industrie du semi-conducteur est spécialisée dans la fabrication massive de produits couteux et délicats. Cela demande une surveillance et un contrôle stricts des machines de production pour détecter des anomalies et défauts le plus tôt possible. Les maintenances préventives (en anglais : preventive maintenance (PM)) planifiées n'ont pas seulement pour but de limiter les pannes et la perte de productivité mais aussi de "prendre soin" des machines après l'observation d'une perte de performance des machines. La planification des PM dans le semi-conducteur est une fonction de la disponibilité des ressources de maintenance, de l'expérience des experts, de la détection des anomalies ou de la perte de performance en compromis avec la productivité.

La Fig. 4.1 montre l'évolution de la dégradation d'une machines avec les seuils théoriques et pratiques entre les états de fonctionnement et de défaillance :  $S0$  théorique,  $S1$  théorique,  $S0$  pratique et  $S1$  pratique. Le seuil neuf de la machine ( $S0$  théorique) n'est pas connu et n'est pas nécessaire au pronostic de défaillance. Le seuil de *panne* de la machine ( $S1$  théorique) est rarement connu pour deux raisons principales : (i) les PM sont réalisées pour limiter les pannes car ce sont des machines couteuses et l'environnement de production et de fonctionnement doivent être stables ; (ii) Ce sont les machines très stables qui peuvent être mises en fonctionnement pendant longtemps ; et l'enregistrement de données chez STMicroelectronics ne permet pas un enregistrement pendant plus de six mois.

L'état de la machine après une maintenance générale (dans le cas d'étude c'est une maintenance préventive) est connu et utilisé comme l'état initial dans la pratique ( $S0$  pratique). L'état de la machine lorsqu'elle est arrêtée pour une PM est connu et utilisé comme le seuil de perte de performance ( $S1$  pratique). Dans le cadre de notre application, le pronostic de défaillance est réalisé donc entre les deux seuils :  $S0$  pratique et  $S1$  pratique.

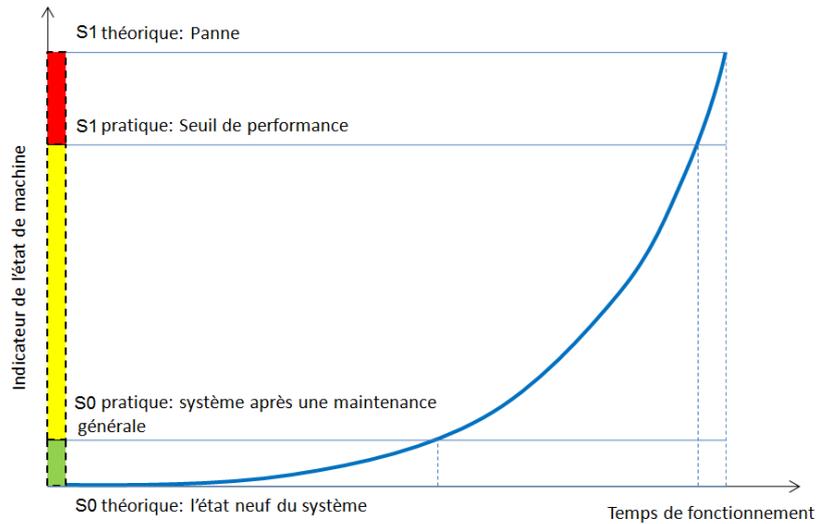


FIGURE 4.1 – Evolution de la dégradation

## 4.2 Application 1 : Description de l'équipement

Le support d'application choisi est une machine de dépôt utilisée dans le processus de fabrication de semi-conducteur, appelée Plasma Enhanced Chemical Vapor Deposition (PECVD). Cette machine est équipée de 19 capteurs détaillés dans la Table 4.1.

Type de capteur	Numéro du capteur
Pression Helium	1, 2
Pression chambre	17
Courant	3
Flux Argon	4, 5
Flux Oxygen	6
Flux SiH4	7, 8
Taux de fuite Helium	9, 10
Puissance directe radio-fréquence	11, 13, 15
Puissance réfléchie radio-fréquence	12, 14, 16
Temperature produit	18
Tension	19

TABLE 4.1 – Ensemble des capteurs

La période d'échantillonnage est de 1 seconde pour une observation. La méthode proposée est ainsi appliquée sur un tenseur de données de 19 capteurs ( $J = 19$ ), 351 observations ( $K = 351$ ), 981 plaques ( $I = 981$ ). Ces données décrivent la dynamique de la machine, du fonctionnement normal (après PM) jusqu'à la défaillance (supposée dans notre étude comme étant la perte de performance).

## 4.3 Génération de l'indice de santé

Les mesures des 200 premières plaques de bonne qualité ( $n = 200$ ) sont utilisées comme données d'apprentissage dans cette étape. La dernière plaque de semi-conducteur est considérée en défaut.

### 4.3.1 Méthode RD-ACP

D'abord, la limite de contrôle  $\beta^2$  de l'indice combiné  $\varphi$  est calculée à partir des données d'apprentissage pour les deux structures : celle basée sur les capteurs et celle basée sur les observations. La Fig. 4.2 montre que l'indice  $\varphi$  de plusieurs plaques et surtout de la dernière plaque dépasse la limite de contrôle. Dans la structure basée sur les capteurs, (la Fig. 4.2-a), la valeur de  $\varphi$  augmente brusquement, cela peut être causé par l'utilisation de la moyenne qui peut affecter la dépendance linéaire des données. Tandis que dans la structure basée sur les observations (la Fig. 4.2-b), la valeur de  $\varphi$  augmente progressivement.

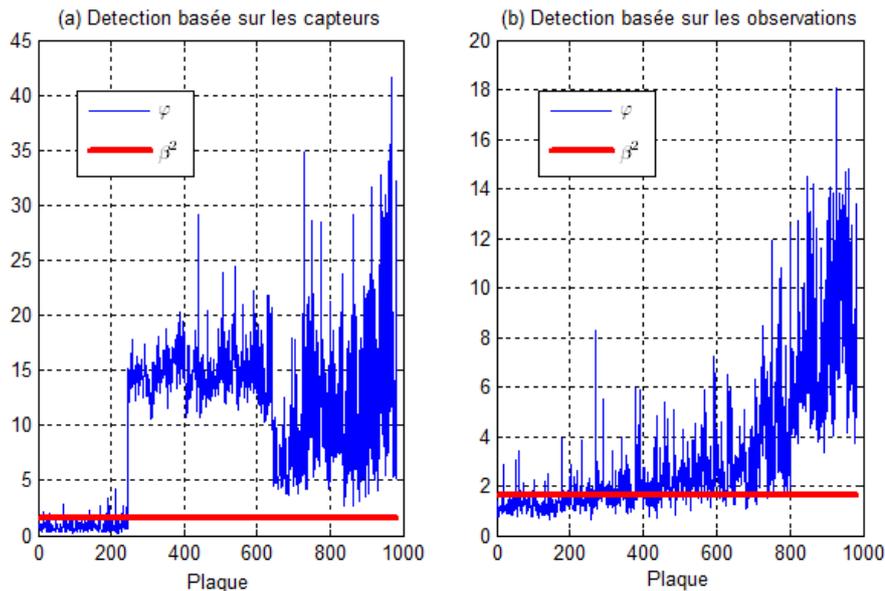


FIGURE 4.2 – Détection de la dégradation

Les données des 250 dernières plaques (732  $\rightarrow$  981) sont les données des plaques dégradées. La Fig. 4.3 présente le résultat du calcul de la direction de dégradation des deux structures (Fig. 2.3). Pour la structure basée sur les capteurs, la Fig. 4.3-a2 montre que les variables identifiées sont les capteurs 1, 2, 8, 9, 10, 18 ; la Fig. 4.3-a1 montre que la reconstruction de cette direction de dégradation donne un indice  $\varphi_r$  intérieur de la limite de contrôle reconstruite  $\beta_r^2$ .

De la même façon pour la structure basée sur les observations, la Fig. 4.3-b2 montre que les variables identifiées sont les observations 100  $\rightarrow$  351. Le choix des variables significatives dans ce cas est basé sur la condition que  $\varphi_r$  soit intérieur à la limite de contrôle reconstruite  $\beta_r^2$ . La Fig. 4.3-b1 montre que la reconstruction de cette direction de dégradation satisfait cette condition.

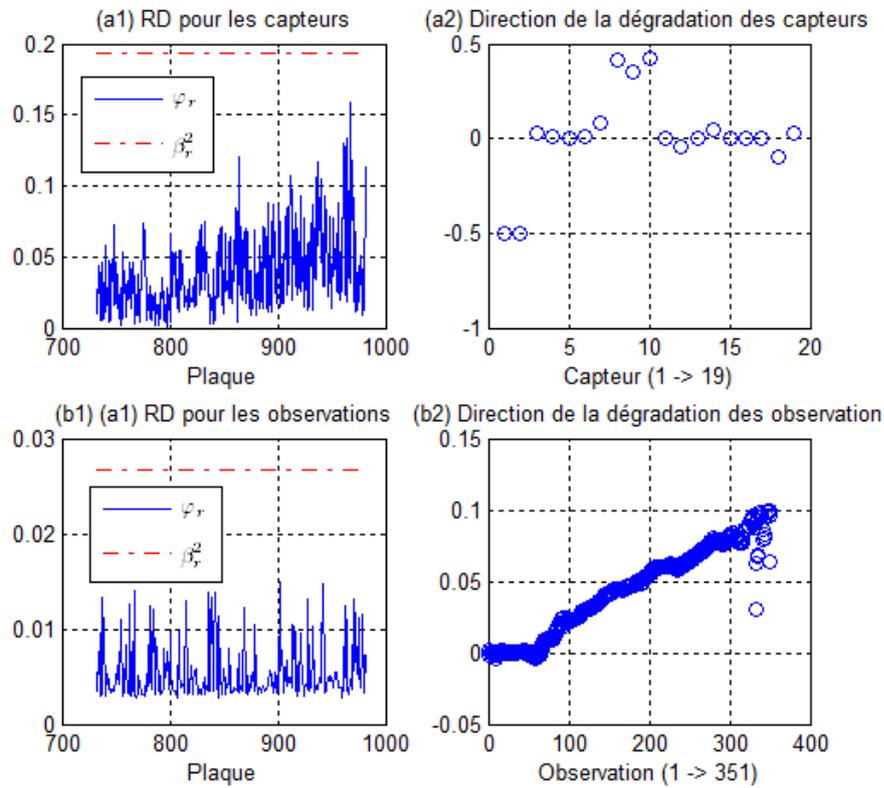


FIGURE 4.3 – L'identification des variables significatives basée sur la reconstruction de la dégradation

Les indices de santé bruts extraits des deux structures sont respectivement présentés dans les Fig. 4.4-a2 et Fig. 4.4-b2. Ils sont générés en utilisant la première des trois CP présentées dans les Fig. 4.4-a1 et Fig. 4.4-b1. On constate que seule la première CP des deux structures décrit un profil progressif, qui peut représenter la dégradation.

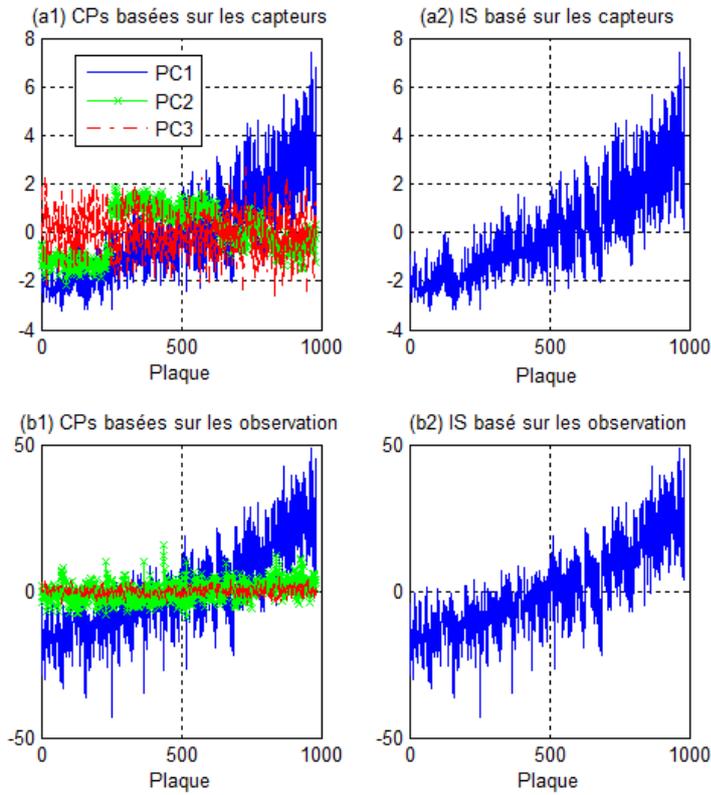


FIGURE 4.4 – Les indices de santé extraits par la méthode RD-ACP

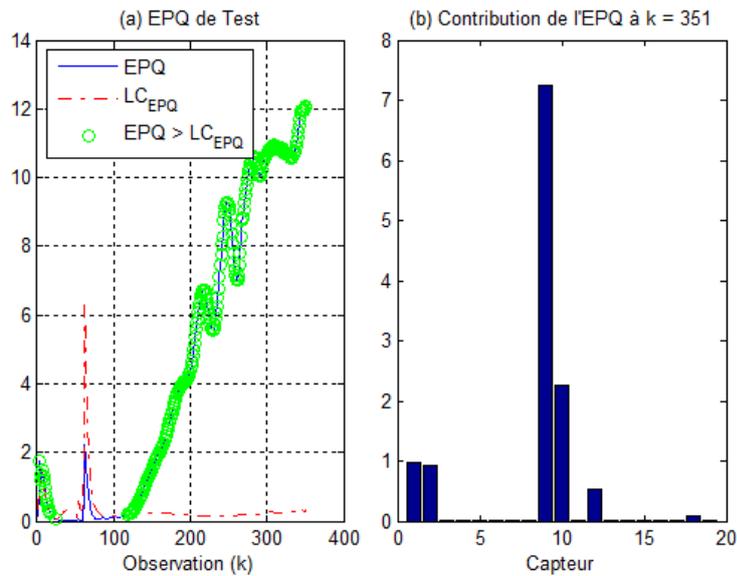


FIGURE 4.5 – (a) Détection de la dégradation de la plaque de test par l'EPQ, (b) Contribution des capteurs portés sur l'EPQ de la plaque à l'observation  $k = 351$

### 4.3.2 Méthode RD-ACPM

La Fig. 4.5 donne le résultat de la détection de dégradation de la plaque de test (équations 2.10-2.11). La Fig. 4.5-a montre que l'EPQ dépasse la limite de contrôle à presque toutes les observations. L'EPQ de l'observation  $k = 351$  est la plus significative, ainsi, la contribution des capteurs sur l'EPQ de la plaque à  $k = 351$  est analysée comme illustré dans la Fig. 4.5-b. Les capteurs potentiels sont 1, 2, 9, 10, 12 et 18.

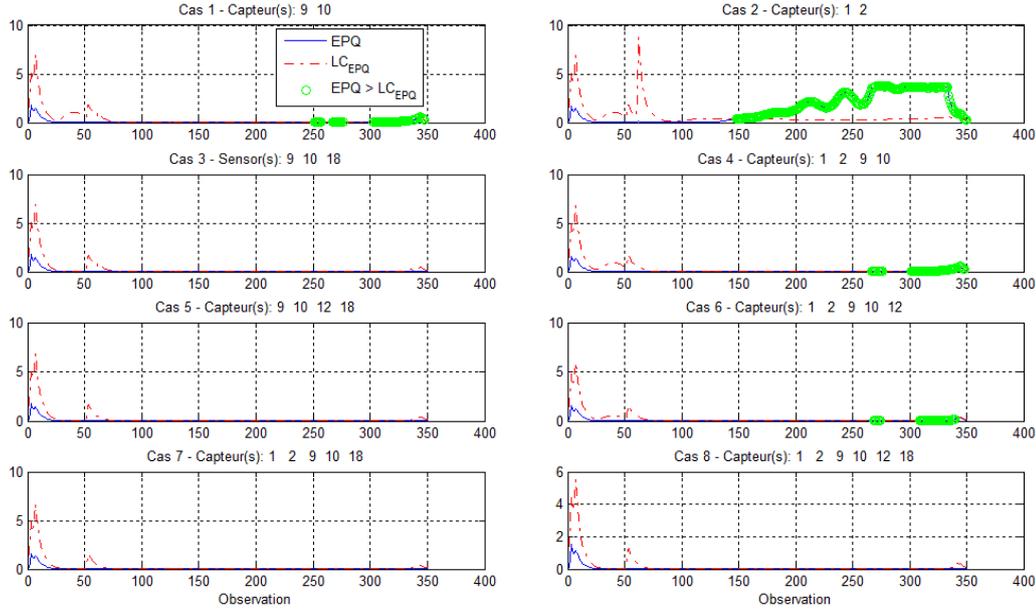


FIGURE 4.6 – Identification des capteurs significatifs par la reconstruction de dégradation

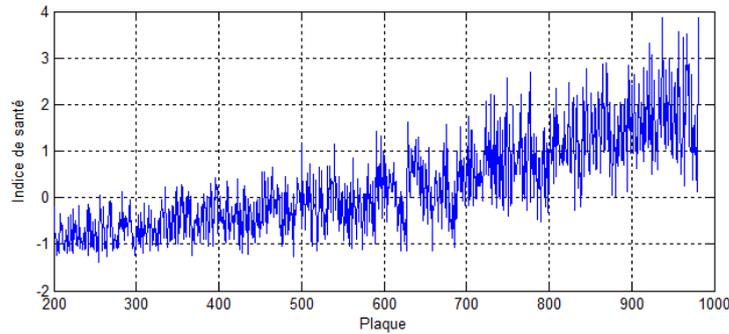


FIGURE 4.7 – L'indice de santé extrait par la méthode RD-ACPM

Afin de vérifier quels capteurs portent la dégradation, différents sous-ensembles de ces capteurs sont utilisés pour construire la matrice de direction de la dégradation. Les résultats de la construction de dégradation (équations 2.17-2.18) de ces sous-ensembles sont donnés dans la Fig. 4.6. On constate que  $EPQ_r \leq LC_{EPQ}$  dans les quatre cas 3, 5, 7, 8. D'ailleurs, le cas 3 est celui qui contient les capteurs communs des cas 5, 7, 8. Donc, les

capteurs identifiés sont les  $\{9, 10, 18\}$ . Ensuite, les points critiques de ces capteurs sont déterminés et l'indice de santé extrait de ces points est illustré dans la Fig. 4.7.

### 4.3.3 Méthode PS-ACP

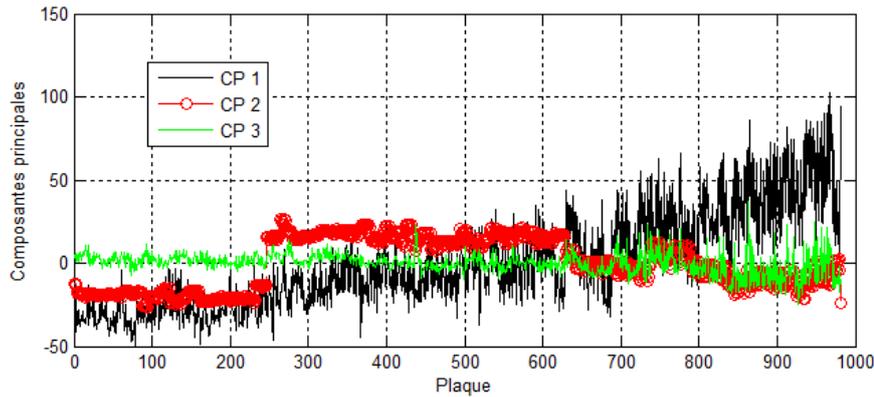


FIGURE 4.8 – Les trois premières composantes principales des points en mouvement

Les 200 premières plaques sont utilisées pour construire les limites inférieure et supérieure LI et LS de chaque point capteur-observation  $(j, k)$  en appliquant les équations (2.23-2.24). Le nombre total des points  $(j, k)$  est  $J \times K = 19 \times 351 = 6669$ . Après la phase 1 de cette méthode, il reste 1527 points en mouvement qui sont notés  $(jm, km)$ . La Fig. 4.8 présente les trois premières composantes principales de ces points en mouvement. La première composante principale (la couleur noire) qui est progressive représente une caractéristique de la dégradation de la machine.

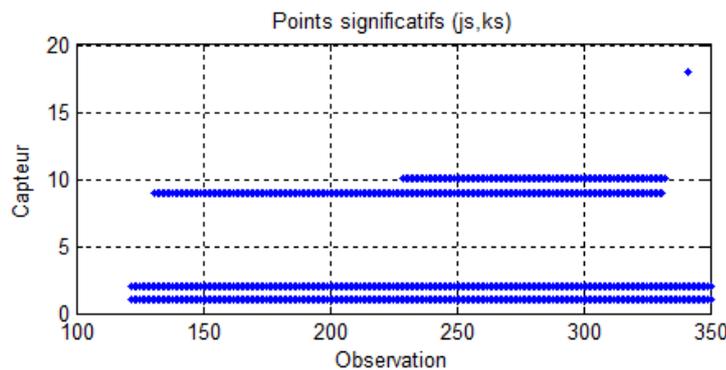


FIGURE 4.9 – Les points significatifs avec  $p = 50$  percentiles

La Fig. 4.9 montre 763 points significatifs  $(js, ks)$  qui sont identifiés par cette méthode, en se basant sur le calcul de corrélation au 50<sup>ème</sup> percentile (les équations 2.28-2.30). Ces points liés aux capteurs 1, 2, 9, 10, 18 sont utilisés pour calculer l'indice de santé brut dont

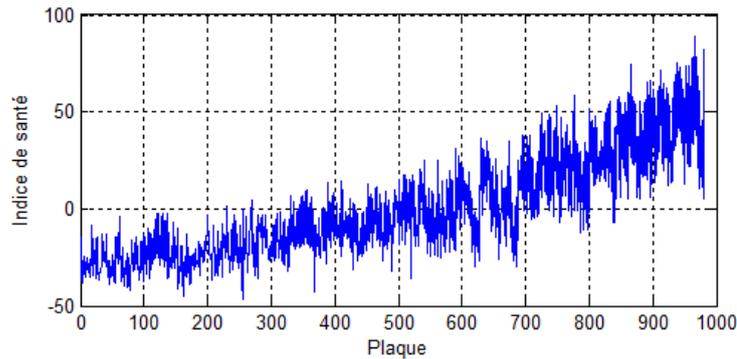


FIGURE 4.10 – L'indice de santé extrait par la méthode PS-ACP

le résultat est montré dans la Fig. 4.10.

#### 4.3.4 Analyse des résultats

La Fig. 4.11 montre les mesures des données de test comparées aux données d'apprentissage sur les 10 des 19 capteurs. Sur les figures de gauche, il y a tous les capteurs qui présentent une variation importante entre les données d'apprentissage et les données de test, ce sont les capteurs 1, 2, 9, 10 et 18. Pour le reste, les données de test sont confondues avec les données d'apprentissage comme illustré dans la partie à droite. Les 5 capteurs à gauche sont tous identifiés par la méthode PS-ACP, mais seulement partiellement identifiés par la méthode RD-ACP ou RD-ACPM.

Pour compléter cette analyse, nous avons fait appel à l'expertise des spécialistes du service défectivité de STMicroelectronics sur cet équipement. Le retour d'expérience est donné sur deux points. Le premier point concerne le profil de la dégradation, les experts ont observé que sur cet équipement, la dégradation présente une variabilité au début de la dégradation plus petite que celle à la fin de la dégradation. Les indices de santé extraits ci-dessus correspondent tous à cette remarque, sauf celui extrait par la méthode RD-ACP basée sur les observations. Le deuxième point concerne les capteurs qui portent la dégradation. Les experts les identifient en utilisant une technique statistique (appelée en anglais : Statistical Process Control) et qui a identifié les capteurs de Pressure of Helium, plus précisément de 120 à 351 observations. Ces capteurs sont donc les capteurs 1 et 2. Parmi les méthodes développées, seule la méthode PS-ACP répond à toutes ces informations, cela signifie que l'indice de santé extrait par la méthode PS-ACP est plus fiable et représente mieux la dégradation que les indices de santé extraits par les autres méthodes. Cependant, la forme de l'IS des méthodes RD-ACPM et PS-ACP sont ressemblants, cela peut être expliqué par le fait qu'il y a une forte corrélation entre les capteurs 1, 2 (le groupe des capteurs de Pression Helium) et les capteurs 9, 10 (le groupe des capteurs de Taux de fuite Helium).

Le résultat obtenu et l'analyse ci-dessus sont récapitulés dans la Table 4.2.

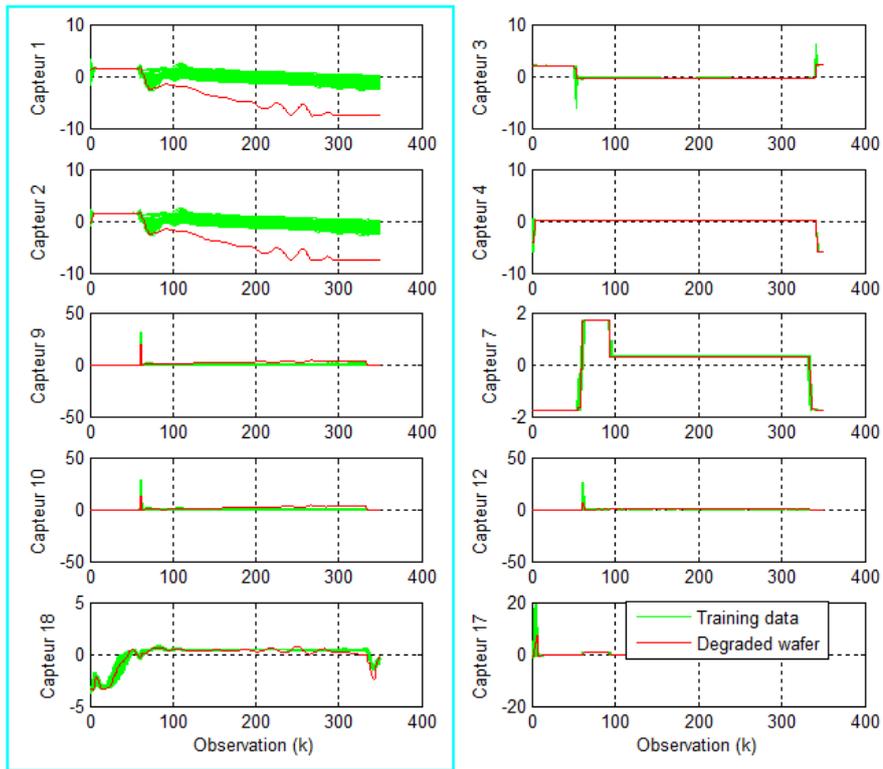


FIGURE 4.11 – Les mesures des données de test comparées aux données d'apprentissage sur les capteurs

	L'IS fiable (expert)	Temps de calcul (Matlab R2012b)	Variables identifiées
RD-ACP basée sur les capteurs	Partiellement	5 secondes	4/5 capteurs identifiés, non observation
RD-ACP basée sur les capteurs observation	Non	6 secondes	observations identifiées mais pas claires, non capteurs
RD-ACPM	Partiellement	42 secondes	3/5 capteurs identifiés
PS-ACP	Oui	15 seconds	5/5 capteurs and correspondant aux observations sont identifiés

TABLE 4.2 – Comparaison le résultat obtenu par les trois méthodes développées

Ainsi, l'indice de santé extrait par la méthode PS-ACP sera ensuite utilisé pour la

prédiction du temps de vie résiduel (RUL) dans la partie suivante.

## 4.4 Pronostic de défaillance

Dans cette partie, l'unité de temps est la durée pour laquelle une plaque est processée sur la machine à surveiller. L'indice de santé brut extrait par la méthode PS-ACP est modélisé par les modèles présentés dans le chapitre 3.

Pour valider la méthode de pronostic développée, deux scénarios d'implémentation sont proposés pour tenir compte de la nature des données disponibles : Scénario (*S.I*) : deux ensembles complets de données (données décrivant la dynamique du système du fonctionnement normal jusqu'à la défaillance totale) sont disponibles. Dans ce cas, le premier ensemble est utilisé pour l'apprentissage et l'autre pour le test. Scénario (*S.II*) : un seul ensemble de données est disponible, dans ce cas une partie des données est utilisée pour l'apprentissage et l'autre partie pour le test.

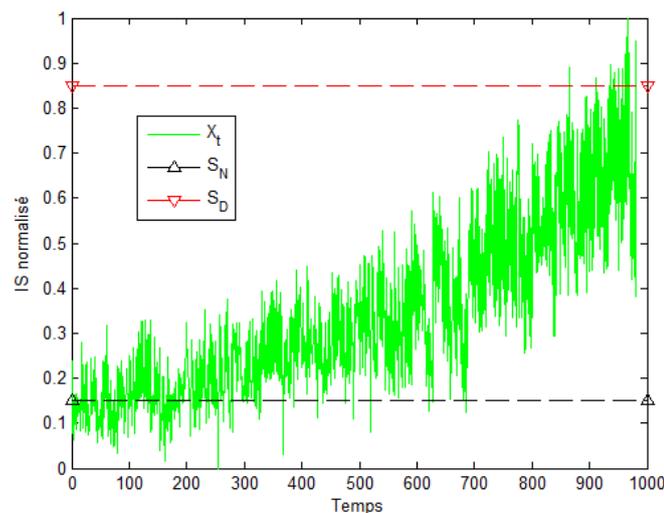


FIGURE 4.12 – L'indice de santé normalisé

### 4.4.1 Pré-traitement de l'indice de santé brut

L'indice de santé brut obtenu est très bruité et un pré-traitement est nécessaire. Le pré-traitement de l'indice de santé brut est fait en appliquant les trois méthodes : la décomposition en modes empiriques (DME) et la décomposition en ondelette (DO) qui ont donné de bons résultats dans l'exemple d'illustration du chapitre 3 ; et la méthode des percentiles développée dans ce travail. La modélisation du profil de la dégradation est réalisée par le processus Wiener et le processus Gamma conventionnel pour les profils générés par la DME et la DO, et le processus Gamma associé à une agrégation des fdp

pour les profils générés par la méthode des percentiles.

L'indice de santé brut est normalisé par l'équation 4.1 :

$$HI_{normalized,t} = \frac{HI_t - \min(HI)}{\max(HI) - \min(HI)} \quad (4.1)$$

Le résultat de cette normalisation est donné dans la Fig. 4.12. Les seuils sont prédéfinis  $S_N = 0.15$  et  $S_F = 0.85$ .

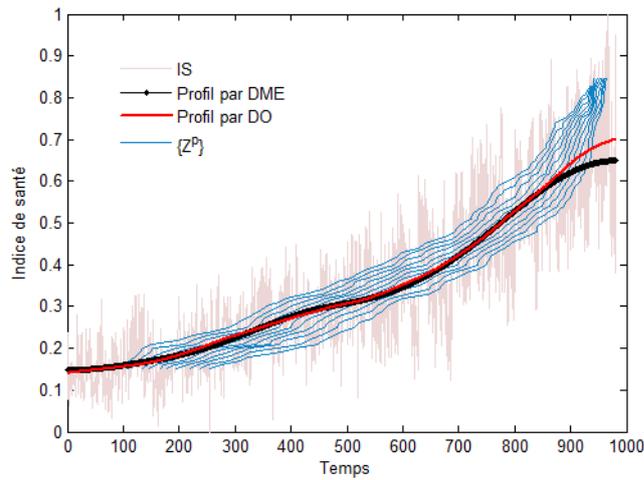


FIGURE 4.13 – Les profils extraits par les techniques DME, DO et la méthode des percentiles sur un ensemble complet de données (Scénario S.I).

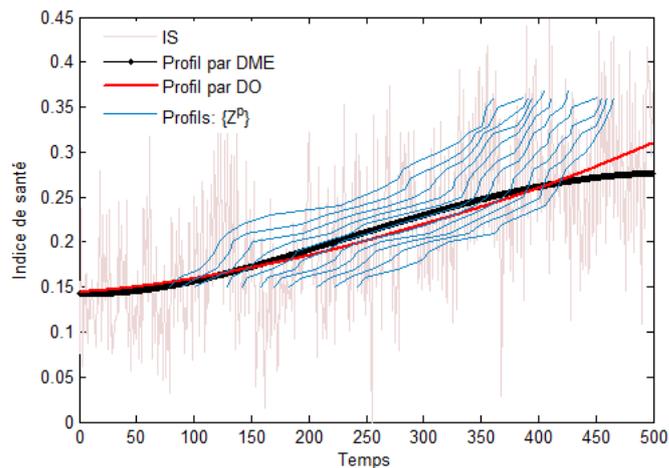


FIGURE 4.14 – Les profils extraits par les techniques DME, DO et la méthode des percentiles sur une partie des données (Scénario II)

La Fig. 4.13 présente les profils extraits par la méthode des percentiles  $\{Z^p\}$  et les deux profils extraits par les techniques Décomposition en Modes Empiriques (DME) et

Décomposition en Ondelettes (DO). On constate que les deux derniers profils sont significativement influencés par les perturbations, par exemple, dans l'intervalle de temps  $500 \rightarrow 600$ ; on constate une dérivation des profils générés par les méthodes DME et DO par rapport à la tendance réelle de l'indice de santé brut.

La Fig. 4.14 illustre les profils extraits de l'indice de santé à l'instant  $t = 499$  (pour le scénario S.II) par les trois méthodes. On remarque la même déformation des profils que dans le Fig. 4.13, ce qui aura un effet sur la modélisation de l'indice de santé et par conséquent sur la prédiction du RUL dans la partie suivante.

## 4.4.2 Modélisation de l'indice de santé et Estimation du RUL

Dans cette section, la prédiction du RUL est réalisée pour les deux scénarios S.I et S.II.

### 4.4.2.1 Pronostic de défaillance pour S.I

L'indice de santé utilisé pour l'apprentissage et celui utilisé pour le test sont donnés dans la Fig. 4.15. L'IS d'apprentissage est utilisé pour l'estimation des paramètres des modèles. L'IS de test est utilisé dans un premier temps en totalité pour calculer le RUL réel qui servira de référence à la validation des méthodes utilisées. Ensuite, à chaque instant de prédiction  $t$ , l'information connue se limite à l'intervalle  $(0, t)$ .

Le temps de défaillance  $\mathcal{T}_D$  est définie comme le temps au bout du quel le profil  $Z^{50}$  atteint le seuil de défaillance  $S_D$  (l'équation 4.2) :

$$\mathcal{T}_D = t|\{Z_t^{50} \geq S_D, Z_{t-1}^{50} < S_D\} \quad (4.2)$$

Dans ce cas,  $\mathcal{T}_D = 938$  pour l'indice de santé de test et son RUL réel à l'instant  $t$  est donc  $\mathcal{T}_D - t$ .

A partir de l'indice de santé d'apprentissage, les méthodes suivantes sont utilisées pour la modélisation : les deux profils extraits par les DME et DO sont modélisés avec les processus de Wiener et le processus Gamma, appelées respectivement Wiener-DME, Wiener-DO, Gamma-DME et Gamma-DO ; les profils  $\{Z^p\}$  sont modélisés par le processus Gamma associé à une agrégation de fdp, et appelée la méthode Gamma-percentiles. Le début de la prédiction, noté  $t_P$  est lancé à l'instant  $t = 200$ .

De la même façon que dans l'exemple d'illustration du chapitre 3, la valeur de  $\mu_t$  obtenue par la modélisation par le processus de Wiener mis-à-jour varie significativement en raison des profils de DME et DO affectés par des perturbations, comme montré dans la Fig. 4.16. Ainsi, le processus de Wiener conventionnel qui permet d'obtenir une valeur fixe de  $\mu$  est utilisé au lieu du processus Wiener mis-à-jour. Les paramètres obtenus sont

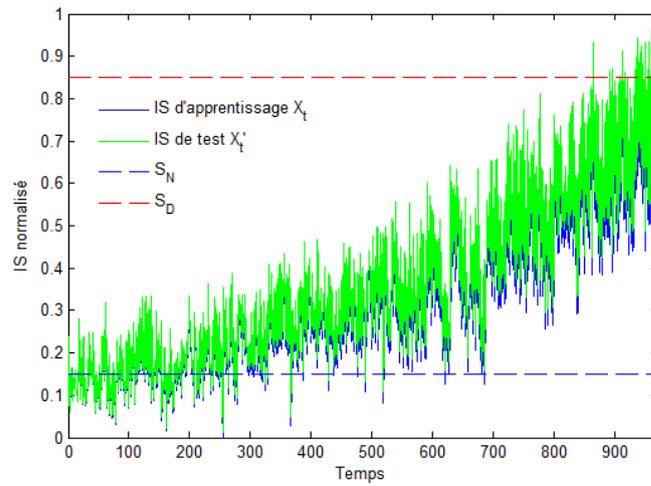


FIGURE 4.15 – Les indices de santé d’apprentissage et de test

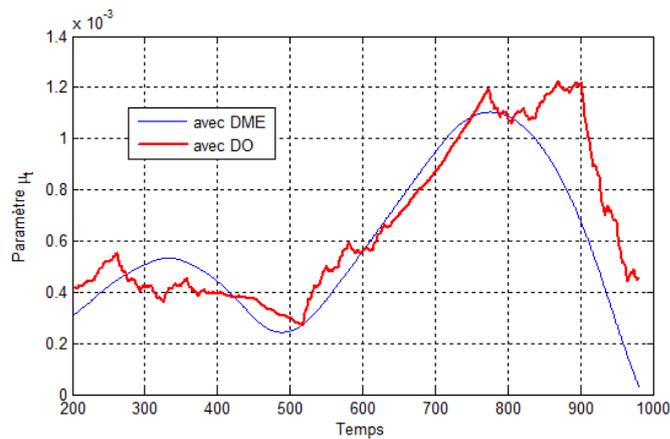


FIGURE 4.16 – L’évolution du paramètre de dérive  $\mu_t$  en appliquant le processus Wiener mis-à-jour sur les deux profils  $Z^{DME}$  et  $Z^{DO}$

	Processus de Wiener $[\mu, \sigma]$	Processus Gamma $[u, c, b]$	Méthode Gamma-percentiles
Paramètres	DME : $[5.4, 4.2] \times 10^{-4}$ DO : $[5.6, 2.9] \times 10^{-4}$	DME : $[5.5 \times 10^3, 0.008, 1.9]$ DO : $[1.7 \times 10^4, 0.32, 1.5]$	$[183, 3.4 \times 10^{-2}, 1.2]$
Erreur quadratique moyenne d’estimation du RUL	avec DME : 522 avec DO : 473	avec DME : 447 avec DO : 325	32

TABLE 4.3 – Comparaison du résultat obtenu par les trois méthodes présentées

donnés dans la Table 4.3. La prédiction du RUL par ce processus donne une erreur importante, comme illustré dans la Fig. 4.17.

Le RUL estimé par la méthode Gamma-percentiles est donné dans la Fig. 4.18. La

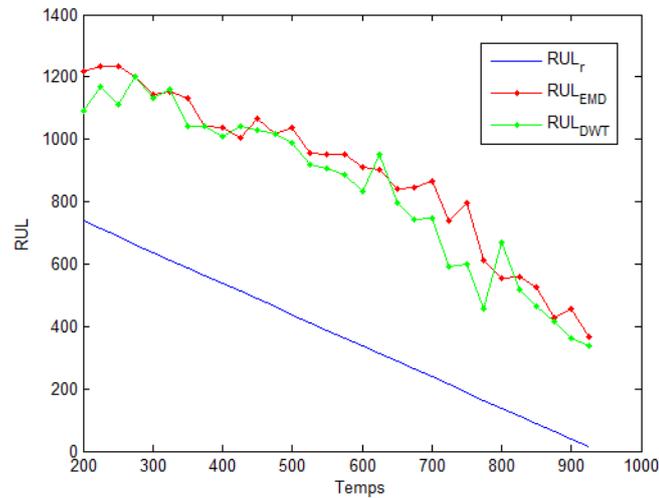


FIGURE 4.17 – Le RUL estimé par le processus de Wiener conventionnel

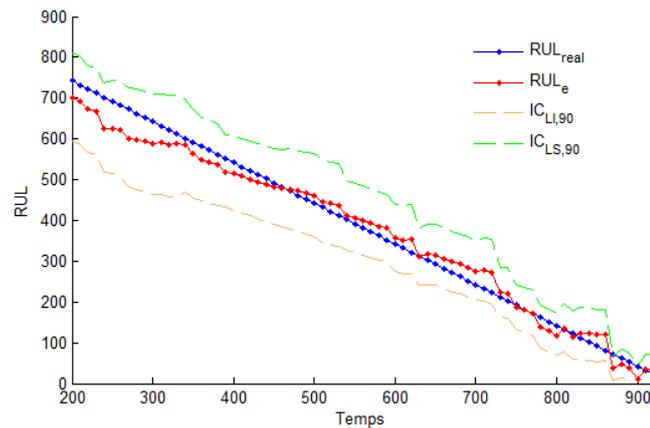


FIGURE 4.18 – Le RUL estimé par la méthode Gamma-percentiles

courbe  $RUL_r$  est le RUL réel. Les courbes  $RUL_e$ ,  $IC_{LI,90}$  et  $IC_{LS,90}$  représentent respectivement le RUL estimé, la limite inférieure et la limite supérieure de l'intervalle de confiance à 90%. La Fig. 4.18 montre que le RUL réel reste toujours dans l'IC à 90% du RUL estimé. L'erreur moyenne quadratique du  $RUL_r$  est faible : 32 unités de temps.

Les RUL estimés par les méthodes Gamma-DME et Gamma-DO sont donnés dans la Fig. 4.19. Elle montre que l'erreur d'estimation du RUL par ces méthodes est significative. Une comparaison du résultat du RUL estimé par le processus de Wiener, processus Gamma et la méthode Gamma-percentiles est résumé dans la Table 4.3. Ce résultat montre que les méthodes Gamma-DME et Gamma-DO donnent une erreur d'estimation importante mais plus petite que celle des méthodes Wiener-DME et Wiener-DO. Il montre surtout l'efficacité de la méthode Gamma-percentiles par rapport aux processus de Wiener et processus Gamma conventionnels.

Pour mieux mettre en évidence son efficacité, nous avons appliqué à la méthode développée des métriques universelles d'évaluation des performances des méthodes de pronostic [131], les métriques appliquées sont : l'Horizon du Pronostic (HP), la Performance  $\alpha - \lambda$  et l'Exactitude Relative (ER) présentées dans le chapitre 1.

La Fig. 4.19 montre l'application de la métrique HP avec une zone d'exactitude  $2\alpha$ .  $\alpha = 50$  unités de temps, équivalant en pourcentage du RUL réel à  $50/(\mathcal{T}_D - t_P) \simeq 6.8\%$ . Les RUL estimés des méthodes Gamma-DME et Gamma-DO ne rentrent pas dans cette zone, mais celui de la méthode Gamma-percentiles reste dans cette zone à partir de l'instant  $t = 310$ . Le HP de cette méthode est donc  $HP = \mathcal{T}_D - 310 = 628$ . A partir de cet instant, le RUL estimé reste dans la zone d'exactitude sur 85% du temps de prédiction. Cette métrique permet à valider l'efficacité de la méthode Gamma-percentiles par rapport aux méthodes et outils existants pour le cas d'étude.

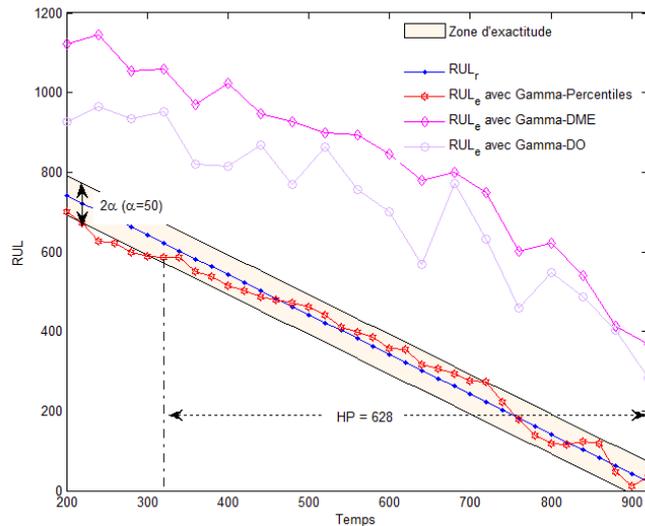
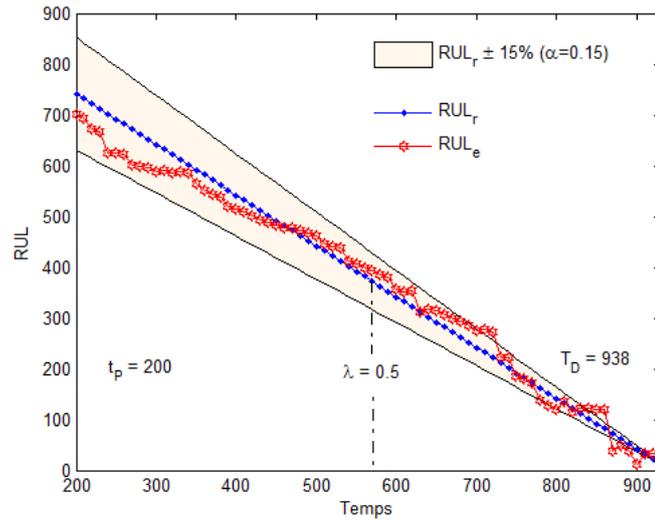


FIGURE 4.19 – Résultat de la métrique Horizon du Pronostic

La Fig. 4.20 montre l'application de la métrique Performance  $\alpha - \lambda$  sur le RUL estimé par la méthode Gamma-percentiles.  $\alpha$  ici n'est pas une quantité de temps mais un pourcentage relié au RUL réel. Dans ce cas,  $\alpha = 15\%$  est appliqué.  $\lambda \in (0, 1)$  est une quantité normalisée qui signifie l'instant de prédiction :  $\lambda = (t - t_P)/(\mathcal{T}_D - t_P)$ .  $\lambda = 0$  au début de la prédiction et  $\lambda = 1$  à la défaillance. La Fig. 4.20 montre que le RUL estimé reste dans l'intervalle des 15% d'exactitude sur la plupart des instants de prédiction. Mais à partir de  $\lambda = 0.87$  ( $t = 840$ ), l'intervalle d'exactitude devient très petit car c'est un pourcentage du RUL réel, ce qui donne un RUL estimé en dehors de l'intervalle d'exactitude. Sachant que l'objectif du pronostic de défaillance est de prédire la défaillance suffisamment en avance pour la planification de la maintenance conditionnelle, la performance obtenue est adéquate.

FIGURE 4.20 – Résultat de la métrique Performance  $\alpha - \lambda$ 

L'Exactitude Relative est similaire à la métrique Performance  $\alpha - \lambda$ , elle évalue l'exactitude par l'équation 1.38. Cependant, son interprétation est plus claire : plus le score est proche de 1, plus l'estimation est exacte. Le résultat de cette métrique est donné dans la Fig. 4.21, elle montre que le score de l'ER reste entre 0.7 et 1 pour  $\lambda \in (0, 0.85)$ , avec une perte d'exactitude à partir de  $\lambda = 0.85$  en raison du fait que le RUL réel devient très petit à l'approche de la défaillance.

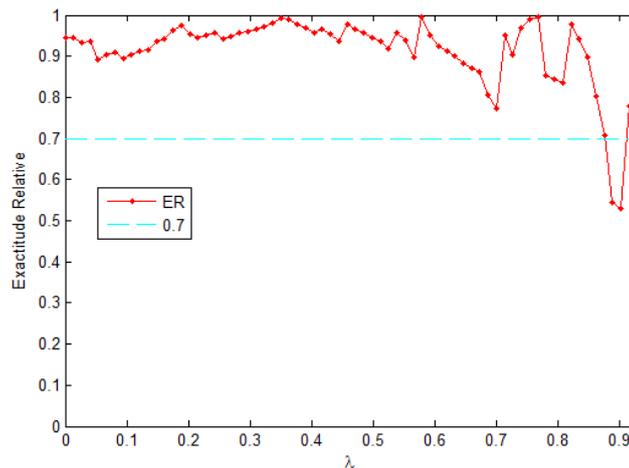


FIGURE 4.21 – Résultat de la métrique Exactitude Relative

#### 4.4.2.2 Pronostic de défaillance pour scénario S.II

Dans cette partie, le jeu de données expérimental est réparti en deux sous-ensembles : celui de l'apprentissage constitué des données relatives aux 499 premiers produits, celui du test constitué des données relatives au reste des produits. Donc, le début de la prédiction est  $t_P = 500$ . Le temps de défaillance  $\mathcal{T}_D = 953$  est calculé également par l'équation 4.2. La méthode Gamma-percentiles est appliquée pour la prédiction du RUL. Le RUL estimé et son intervalle de confiance à 90% sont donnés dans la Fig. 4.22. Elle montre que le RUL réel reste dans l'IC à partir de l'instant  $t = 730$ .

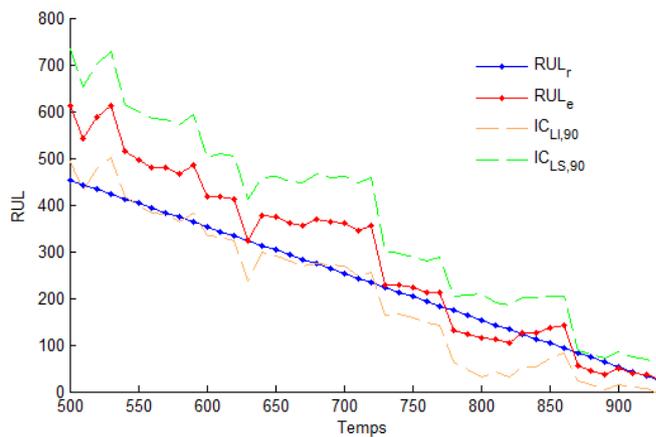


FIGURE 4.22 – Le RUL estimé et son IC à 90% comparés au RUL réel

Ensuite, les métriques de performance sont également appliquées. La Fig. 4.23 montre qu'avec  $\alpha = 50$ , le HP est de 223 unités de temps, soit 49% du temps de prédiction.

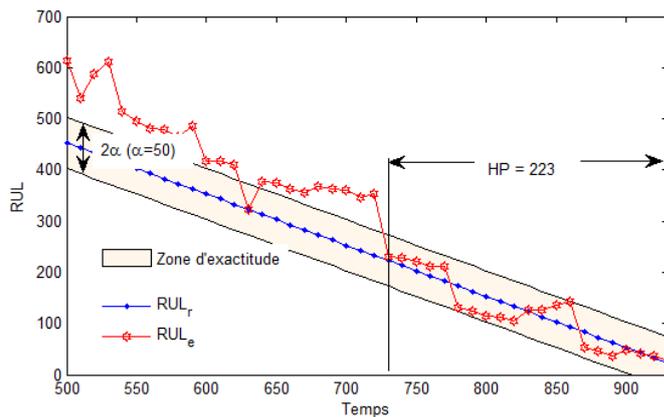
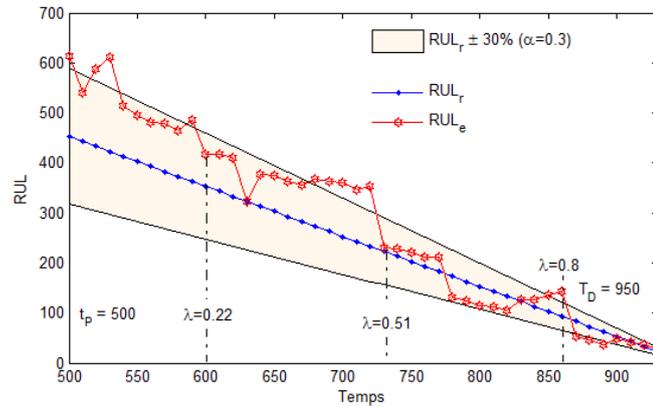


FIGURE 4.23 – Résultat de la métrique Horizon du Pronostic

Les résultats de l'application de la performance  $\alpha - \lambda$  et le l'ER sont respectivement donnés dans les figures 4.24 et 4.25. Ces résultats confirment l'efficacité de la méthode proposée. Ils sont néanmoins moins exacts que ceux obtenus avec le scénario S.I, ce qui est normal, car la méthode proposée est basée sur la technique d'apprentissage, ainsi, plus

FIGURE 4.24 – Résultat de la métrique Performance  $\alpha - \lambda$ 

l'ensemble de données d'apprentissage est riche et complet plus la méthode proposée est efficace.

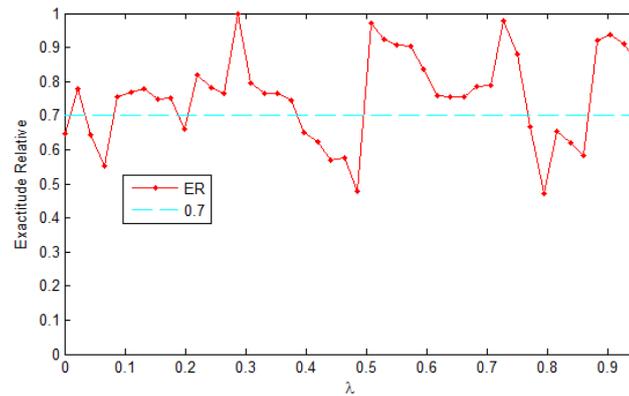


FIGURE 4.25 – Résultat de la métrique Exactitude Relative

## 4.5 Application 2

Pour confirmer l'efficacité de l'approche de pronostic développée dans ce travail de thèse, nous l'avons appliqué à un deuxième équipement appelé Sub-atmospheric chemical vapor deposition (SACVD), équipé par 7 capteurs détaillés dans la Table 4.4. La méthode proposée est ainsi appliquée sur un tenseur de données de 7 capteurs ( $J = 7$ ), 276 observations ( $K = 276$ ), 590 plaques ( $I = 590$ ), à partir du début de la dégradation (S0 pratique) jusqu'à la perte de performance (S1 pratique).

Les points significatifs sont donnés dans la Fig. 4.26 avec  $p = 50$  percentiles, ils sont

Type de capteur	Numéro du capteur
Valeur d'Ozone concentré	1
Contrôleur de flux TEOS	2
Contrôleur de masse O2	3
Pression chambre	4
Pression Cryogenic	5
Valve régulateur	6
Injecteur voltage TEOS	7

TABLE 4.4 – Ensemble des capteurs

liés aux deux capteurs *Pression Cryogenic* et *Injecteur voltage TEOS*. Une analyse de corrélation avec  $p = 80$  percentiles, montre que les points significatifs sont les mesures du capteur 5 - *Pression Cryogenic*, donné dans la Fig. 4.27. L'avis de l'expert montre que les dégradations typiques de la chambre de cette machine, comme l'encrassement de la chambre ou un problème de pompage affectent généralement les mesures de *Pression Cryogenic*. D'ailleurs, le cycle de vie du capteur *Injecteur voltage TEOS* est beaucoup plus long que le cycle de vie du capteur *Pression Cryogenic* et il est moins affecté par ces dégradations. Par conséquent, ce retour d'information de l'expert permet de valider le résultat obtenu.

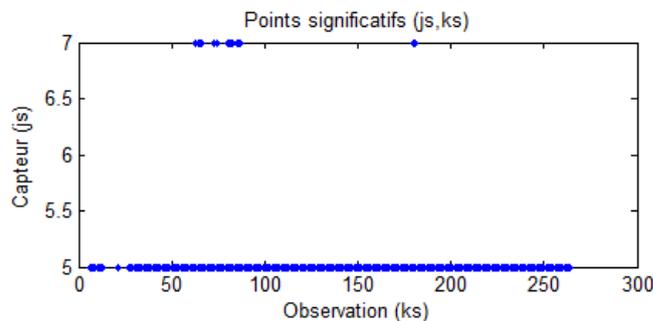


FIGURE 4.26 – Les points significatifs avec  $p = 50$  percentiles

Les trois premières composantes principales sont montrées dans la Fig. 4.28, où on constate que la première composante principale montre une tendance progressive mais les deux autres CP ne la montrent pas. Ce cas valide encore une fois le choix de la première composante principale comme indice de santé.

Ensuite, la méthode des percentiles est appliquée sur l'indice de santé normalisé et le résultat est donné dans la Fig. 4.29. Le seuil  $S_D = 0.85$  est prédéfini comme dans l'application précédente. Le temps de défaillance réel est donc trouvé  $\mathcal{T}_D = 471$ .

Dans cette application, seul le scénario S.II est appliqué, correspondant au pronostic de défaillance avec les données incomplètes et le processus de prédiction du RUL est mis

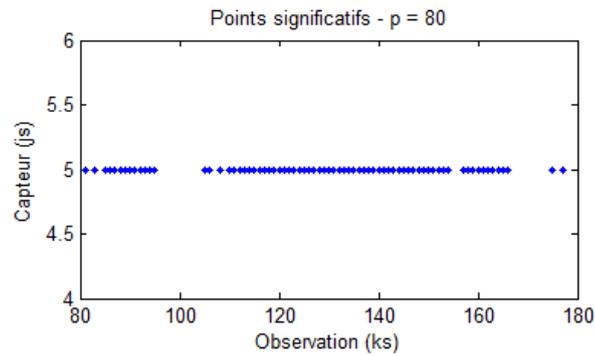
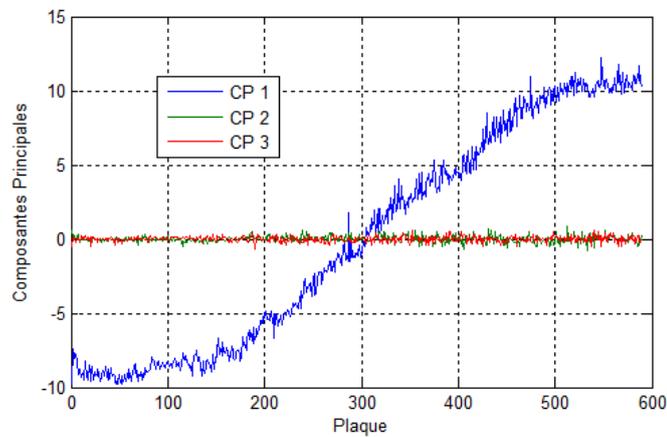
FIGURE 4.27 – Les points significatifs avec  $p = 80$  percentiles

FIGURE 4.28 – Les trois premières composantes principales des points significatifs

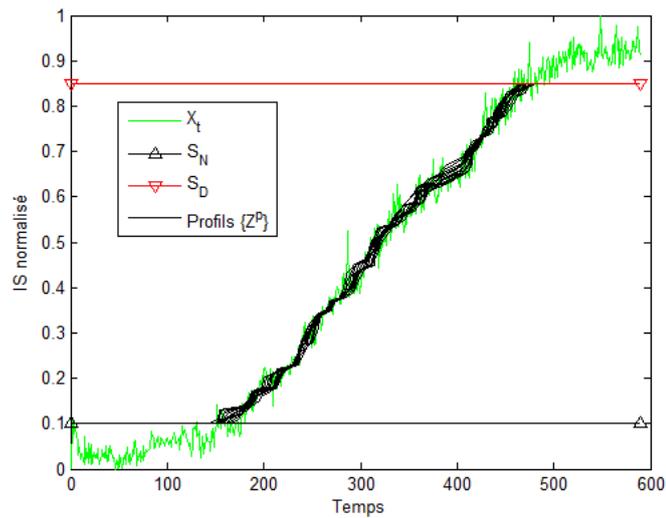


FIGURE 4.29 – Les profils extraits par la méthode des percentiles sur l'indice de santé

à jour à chaque inspection quand les nouvelles données sont disponibles. Le début de la prédiction est  $t_P = 300$ , les données de l'apprentissage constituent donc les données relatives aux 299 premiers produits. La méthode Gamma-percentiles est appliquée pour la prédiction du RUL. Le RUL estimé et son intervalle de confiance à 90% sont donnés dans la Fig. 4.30. Elle montre que le RUL réel reste dans l'IC à partir de l'instant  $t = 395$ .

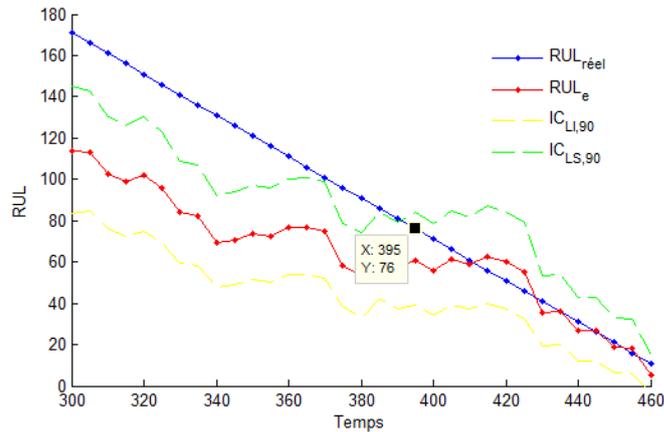


FIGURE 4.30 – Le RUL estimé et son IC à 90% comparés au RUL réel

Les métriques de performance sont également appliquées. La Fig. 4.31 montre qu'avec  $\alpha = 20$ , le HP est de 76 unités de temps, soit 44% du temps de prédiction. Les résultats de l'application de la performance  $\alpha - \lambda$  et l'Exactitude Relative sont respectivement donnés dans les figures 4.32 et 4.33. Elles montrent qu'à partir de l'instant  $\lambda = 0.56$ , le RUL estimé reste dans l'intervalle des 20% d'exactitude. Ces résultats confirment l'efficacité de la méthode proposée.

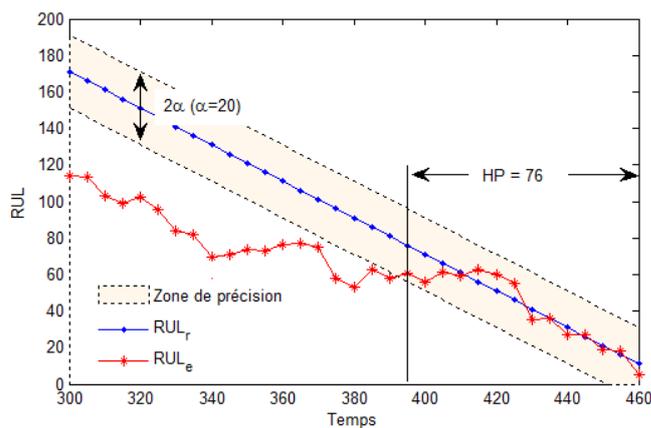


FIGURE 4.31 – Résultat de la métrique Horizon du Pronostic

Les métriques de performance du pronostic présentées permettent de non seulement comparer la performance des différentes méthodes mais aussi de vérifier si une méthode

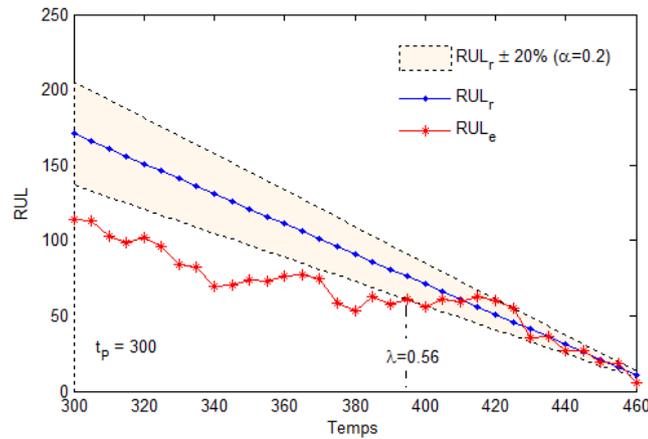
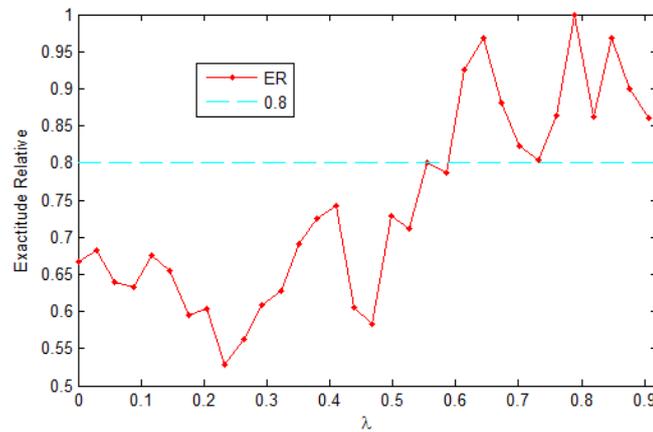
FIGURE 4.32 – Résultat de la métrique Performance  $\alpha - \lambda$ 

FIGURE 4.33 – Résultat de la métrique Exactitude Relative

répond aux performances souhaitées. Parmi elle, la métrique Horizon du Pronostic permet de vérifier si une méthode répond à la performance  $HP \pm \alpha$  : est-ce que l'HP est un temps suffisant pour une planification de maintenance efficace avec l'exactitude  $\pm \alpha$  ? Autrement dit, est-ce qu'on peut connaître la défaillance suffisamment à l'avance (de HP unités de temps) avec une exactitude  $\pm \alpha$  ? Cette métrique est très pratique dans l'implémentation des méthodes dans le secteur industriel. Une interprétation des résultats obtenus dans le contexte de la fabrication du semi-conducteur est nécessaire pour l'estimation de la performance de l'approche de pronostic développée, les résultats obtenus de l'application de la métrique Horizon du Pronostic sont donc choisis pour l'interprétation.

## Interprétation des résultats

Dans l'Application 1, le temps de la fabrication de l'ensemble de 981 plaques échantillonnées est de 40 jours. Ainsi, dans le scénario 1 où l'estimation du RUL est réalisée sur

l'IS de test, le temps du début de la dégradation jusqu'à la défaillance pour l'IS de test est de 38 jours (soit 938 plaques). L'Horizon du Pronostic est de  $628 \pm 50$  plaques, soit de  $25.6 \pm 2$  jours de fabrication.

Dans le scénario 2 de l'Application 1, l'apprentissage du modèle et l'estimation du RUL sont réalisés sur un seul IS où le temps total du début des données jusqu'à la défaillance est de 39 jours (le temps de défaillance est à la 953<sup>eme</sup> plaque). L'Horizon du Pronostic est de  $223 \pm 50$  plaques, soit de  $9 \pm 2$  jours de fabrication.

De la même façon, dans l'Application 2, le temps total est de 51 jours pour la fabrication de l'ensemble de 590 plaques échantillonnées. L'Horizon du Pronostic est donc de  $7 \pm 1.7$  jours. L'interprétation des résultats est résumée dans la table suivante :

	Temps total	Horizon du Pronostic $\pm \alpha$
Application 1 - Scénario 1	38 jours	$25.6 \pm 2$ jours
Application 1 - Scénario 2	39 jours	$9 \pm 2$ jours
Application 2 - Scénario 2	51 jours	$7 \pm 1.7$ jours

TABLE 4.5 – Interprétation des résultats obtenus

Dans la fabrication du semi-conducteur, les Horizons du Pronostic obtenus ci-dessus sont suffisamment larges et précis pour planifier une maintenance efficace.

## 4.6 Conclusion

### 4.6.1 Applications considérées

L'approche du pronostic de défaillance développée dans les chapitres 2 et 3 a été appliquée dans ce chapitre sur des équipements industriels de fabrication de semi-conducteur. Premièrement, l'indice de santé brut est généré en utilisant les méthodes présentées dans le chapitre 2 puis utilisé pour l'estimation du RUL en utilisant les méthodes détaillées dans le chapitre 3. Les résultats obtenus montrent que la génération de l'indice de santé brut par la méthode SP-ACP, associée à la méthode Gamma-percentiles pour l'estimation du RUL est l'approche qui donne le meilleur résultat par rapport à la robustesse aux bruits et perturbations, exactitude de l'estimation, temps de calcul et facilité de mise en oeuvre.

L'approche de pronostic multi-modes n'a pas été appliquée dans ce chapitre sur les données réelles car l'ensemble de données nécessaires à l'application n'est pas disponible. La validation de cette méthode sur des données expérimentales fera l'objet des travaux de recherche à venir.

### 4.6.2 Perspective d'implémentation dans le milieu industriel

Une des finalités industrielles de ce travail de thèse est de remplacer à terme la stratégie de maintenance préventive (PM) par une stratégie de Maintenance Conditionnelle (CM), grâce à la méthode développée dans ce travail.

Les données et résultats de la première PM sur l'équipement seront utilisés pour calculer les seuils S0 et S1 pratiques et l'identification des paramètres du processus Gamma, l'algorithme proposés sera ensuite implémenté et aura comme premier objectif d'estimer le RUL avant que l'équipement n'arrive à l'état de santé enregistré lors de la première PM (seuil S1). Cela permettra à l'industriel de planifier les autres arrêts pour maintenance en fonction du RUL annoncé.

La méthode des points significatifs peut être utilisée pour ajuster le seuil S1 en donnant à l'industriel les valeurs des capteurs et observations pertinentes correspondant à cet état. L'expertise de l'industriel sera ensuite utilisée pour évaluer les valeurs trouvées et ajuster le seuil S1 pour être au plus près de la défaillance, sachant que l'IC assurera les marges de sécurités requises.

#### Contraintes de mise en oeuvre

Les contraintes de mise en oeuvre de la méthode développée dans les unités de production de STMicroelectronics sont principalement liées aux techniques d'acquisition et de traitement des données en ligne, que l'on peut résumer comme suit :

- Le logiciel d'enregistrement induit des erreurs dans les données collectées. Un exemple d'incident logiciel est donné dans le Fig. 4.34, il affecte les données collectées entre le produit 2844 et le produit 4411. Ce type d'incident n'affecte pas la qualité des produits et n'est traité qu'après un certain temps.

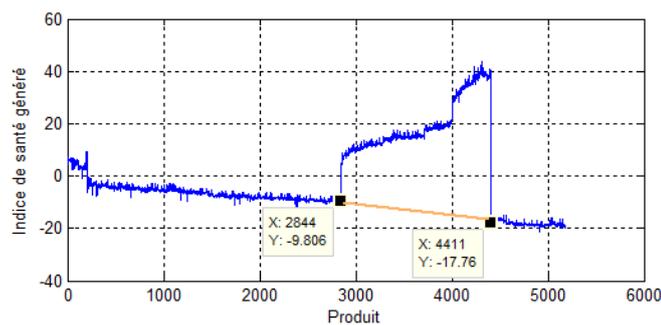


FIGURE 4.34 – Exemple d'un incident de logiciel affectant l'indice de santé généré

- L'implémentation de l'approche développée nécessite un tenseur de données, de même taille pour tous les capteurs sur tous les produits, ce qui n'est pas le cas des données disponibles car : (i) les mesures des capteurs ne sont pas toutes échantillonnées à la même fréquence : la fréquence d'échantillonnage dépend de la dynamique de l'objet physique mesuré et de la nature du capteur. Par exemple : la dynamique

de la température évolue plus lentement que celle de la tension, donc leur fréquences d'échantillonnage sont différentes. Cela requiert un algorithme pour remettre les mesures des capteurs sur un même nombre d'observations ; (ii) l'incertitude liée à la durée du traitement des mêmes produits sur un même équipement ; qui donne lieu à des vecteurs de mesure de tailles différentes. Ce qui va donc nécessiter la mise en place d'algorithmes d'alignements de données pour avoir des données de même taille dans le tenseur.

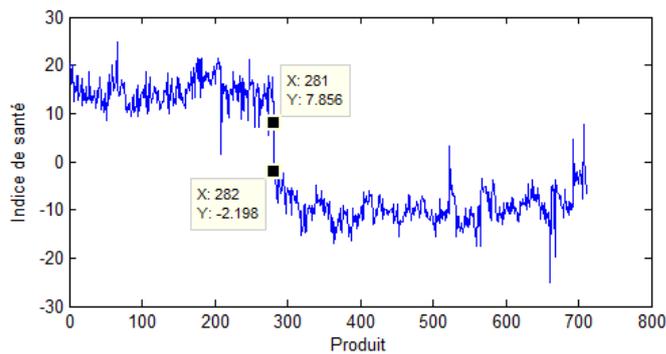


FIGURE 4.35 – Exemple de l'indice de santé avec une pause de machine

- La présence assez souvent d'alarmes et de pauses machine. Chaque alarme est liée à un paramètre à surveiller et signale une anomalie de fonctionnement. Les alarmes sont classées en deux catégories :
  - *Alarmes strictes* : si l'anomalie peut provoquer un rejet des produits ou une perte de performance importante. Ce type d'alarmes est suivi d'une CM ou PM.
  - *Alarmes non strictes* : si l'anomalie est peu importante et son traitement peut attendre les prochaines interventions.

Les pauses machine peuvent être liées soit à une baisse de productivité, soit à des pannes locales qui n'affectent pas les mesures (arrêt d'une pompe, un robot de transport, etc.) soit des interventions (PM ou CM). Il est difficile dans ces conditions d'avoir pour l'apprentissage une fenêtre d'observation sans alarmes ou pauses. La Fig. 4.35 illustre une fenêtre d'observation entre deux PM qui contient une pause de deux semaines entre les produits 281 et 282 à cause d'une baisse de productivité. Lors de la remise en fonctionnement (produit 282), l'équipement a subi un réglage de ces paramètres de régulation, provoquant un saut important des caractéristiques entre le produit 281 et le produit 282.





# Conclusion générale

## Conclusion

Les travaux de recherche présentés dans ce manuscrit ont été réalisés dans le cadre du projet industriel MAGE, et concernent le développement d'une approche de pronostic de défaillance applicable à des systèmes de production en série. L'objectif premier de ce travail de thèse est donc atteint grâce à la proposition d'une méthode originale de pronostic de défaillance des systèmes de production en série, validée en simulation et sur un équipement de production de semi-conducteur.

La méthode de pronostic développée dans ce manuscrit a une structure horizontale organisée en trois modules, et une méthode de calcul originale a été développée dans chaque module. La première difficulté du pronostic de ce contexte réside dans l'extraction des caractéristiques de la dégradation de l'équipement à partir d'un tenseur de données. Cette problématique a été résolue par le développement de trois méthodes de réduction de données. La méthode appelée PS-ACP est sans doute la plus originale. Pour montrer l'efficacité de cette méthode par rapport aux autres méthodes, une analyse comparative a été réalisée sur un exemple d'illustration dans le chapitre 2 et les résultats obtenus sont satisfaisants.

L'approche proposée est partie de l'idée d'une génération des caractéristiques de la dégradation, agrégées en un seul indice à partir du tenseur de données, puis la modélisation de sa tendance pour l'estimation du RUL. Le profil commun de l'indice de santé réel présente une tendance progressive noyée dans le bruit et la perturbation, nous avons donc proposé dans le chapitre 3 une méthode de pré-traitement appelée méthode des percentiles pour générer des profils monotones qui décrivent la dégradation. Contrairement aux méthodes de pré-traitement temporelles et fréquentielles existantes, la méthode proposée n'engendre pas de perte d'information et ne provoque pas une déformation du profil de la dégradation. La méthode des percentiles est associée au processus Gamma pour la modélisation de la dégradation et l'estimation du RUL. L'approche de pronostic développée dans ce chapitre a été appliquée sur les données des équipements de production industrielle et les résultats sont analysés et comparés à ceux obtenus par d'autres méthodes. L'analyse comparative basée sur la robustesse aux perturbations, l'exactitude du RUL estimé et la facilité d'implémentation a montré l'efficacité de l'approche proposée.

## Perspective

L'implémentation sur une ligne de production de semi-conducteur chez STMicroelectronics est une des perspectives prévues pour ce travail de recherche. Pour le faire, les points suivants devront faire l'objet d'une étude approfondie :

- L'influence de processus de régulation doit être analysés et prise en compte.
- La méthode proposée dans ce manuscrit nécessite une étape d'apprentissage réalisée hors ligne, l'adaptation de cette approche à l'apprentissage en ligne est une des perspectives de recherche à développer.
- Les seuils de détection d'un début de dégradation et de défaillance sont prédéfinis dans ce travail. Il existe dans la littérature des méthodes permettant le calcul de ces seuils mais l'analyse de la robustesse de ces méthodes et leur implémentation dans le milieu industriel reste d'actualité.
- Bien que la méthode des percentiles peut être appliquée en tenant compte de tous les percentiles, la formalisation du choix du percentile pour affiner l'extraction de la tendance de dégradation est nécessaire.
- Une étude du cas où les perturbations ne sont pas indépendantes avec la dégradation dans l'extraction de l'indice de santé; et une étude du cas où l'hypothèse de monotonie n'est pas vérifiée dans la modélisation de la dégradation sont deux des perspectives théoriques à réaliser.

Dans ce manuscrit, un travail de recherche sur le développement d'une méthode de pronostic de défaillance des systèmes à fonctionnement multi-modes a été proposé et des résultats préliminaires sont présentés. La validation de cette approche sur un exemple expérimental sera réalisée dans des travaux de recherche futurs.



## Abréviation

2D	Deux dimensions
3D	Trois dimensions
ACP	Analyse en Composantes Principales
CP	Composantes Principales
DME	Décomposition en Modes Empiriques
DO	Décomposition en Ondelettes
EPQ	Erreur de prédiction quadratique
EMV	Estimation du maximum de vraisemblance
fdp	Fonction de Densité de Probabilité
IA	Intelligence Artificielle
IC	Intervalle de Confiance
IS	Indice de Santé
LC	Limite de Contrôle
MM	Multi-modes
RN	Réseaux de neurones
RUL	Remaining Useful Life (Temps de vie résiduel)
RD-ACP	Reconstruction de la dégradation par l'ACP
RD-ACPM	Reconstruction de la dégradation par l'ACP Multi-voies
PECVD	Plasma Enhanced Chemical Vapor Deposition
SACVD	Sub-Atmospheric Chemical Vapor Deposition
PS-ACP	Points significatifs combinés avec l'ACP
UM	Uni-mode



## Références bibliographiques

- [1] L. Mönch, J.W. Fowler, S. Dauzère-Pérès et al., "A survey of problems, solution techniques, and future challenges in scheduling semiconductor manufacturing operations", *Journal of Scheduling*, pp. 583-599, 2011.
- [2] F. Monchy, J.P. Vernier, "Maintenance : Méthodes et organisations", *Livre : Dunod/L'Usine Nouvelle - 3ème édition*, 2012.
- [3] C.S. Byington, M.J. Roemer and T. Galie, "Prognostic enhancements to diagnostic systems for improved condition-based maintenance [military aircraft]", *Aerospace Conference Proceedings, IEEE*, vol. 6, pp. 2815-2824, 2002.
- [4] P.C. Paris and F. Erdogan, "A critical analysis of crack propagation laws" , *Journal of Fluids Engineering*, vol.85, no. 4, pp. 528-533, 1963.
- [5] A.K.S. Jardine, P.M. Anderson and D.S. Mann, "Application of the weibull proportional hazards model to aircraft and marine engine failure data" , *Quality and Reliability Engineering International*, vol.3, no. 2, pp. 77-82, 1987.
- [6] A. Zuashkiani, A. Banjevic and A. Jardine, "Incorporating expert knowledge when estimating parameters of the proportional hazards model" , *Reliability and Maintainability Symposium*, vol.3, no. 2, pp. 402-408, 2006.
- [7] X. Zhao, M. Fouladirad, C. Brenguer and L. Bordes, "Condition-based inspection/replacement policies for non-monotone deteriorating systems with environmental covariates" , *Reliability Engineering and System Safety*, vol.95, no. 8, pp. 921-934, 2010.
- [8] S. Sankararaman, Y. Ling, C. Shantz and S. Mahadevan, "Uncertainty quantification in fatigue damage prognosis" , *Annual conference of the prognostics and health management society*, pp. 1-13, 2009.
- [9] M.E. Orchard and G.J. Vachtsevanos, "A particle filtering approach for on-line failure prognosis in a planetary carrier plate" , *International Journal of Fuzzy Logic and Intelligent Systems*, vol.7, no. 4, pp. 221-227, 2007.
- [10] M.V.S Pereira, F.A.I Darwish, A.F. Camarao et al., "On the prediction of fatigue crack retardation using Wheeler and Willenborg models" , *Materials Research*, vol.10, no. 2, pp. 101-107, 2007.

- [11] O.E. Wheeler, "Spectrum loading and crack growth", *Journal of Basic Engineering*, vol. 94, pp. 181-186, 1972.
- [12] D. Gucik-Derigny, "Contribution au pronostic des systèmes à base de modèles : théorie et application" , *Thèse préparée au Laboratoire LSIS - UMR CNRS 6168, Université Paul Cézanne - Aix-Marseille 3*, 2011.
- [13] J.Z. Sikorska, M. Hodkiewicz and L. Ma, "Prognostic modelling options for remaining useful life estimation by industry" , *Mechanical Systems and Signal Processing*, vol.25, pp. 1803-1836, 2011.
- [14] O.E. Dragomir, R. Gouriveau, F. Dragomir, E. Minca, N. Zerhouni,"Review of prognostic problem in condition-based maintenance" *European Control Conference (ECC'09)*, pp. 1585-1592, 2009.
- [15] P. Wang, G. Vachtsevanos, "Fault prognostics using dynamic wavelet neural networks", *AAAI Technical Report*, 1999.
- [16] A. Mathur, K.F. Cavanaugh, K.R. Pattipati, P.K. Willett, T.R. Galie, "Reasoning and modeling systems in diagnosis and prognosis", *Aerospace/Defense Sensing, Simulation, and Controls, International Society for Optics and Photonics*, pp. 194-203, Jul. 2001.
- [17] M. Lebold, M., M. Thurston, "Open standards for condition-based maintenance and prognostic systems", *Maintenance and Reliability Conference (MARCON)*, pp. 6-9, May 2001.
- [18] A.K. Jardine, D. Lin, D. Banjevic, "A review on machinery diagnostics and prognostics implementing condition-based maintenance", *Mechanical systems and signal processing*, vol. 20, no. 7, pp. 1483-1510, 2006.
- [19] A. Muller, M.C. Suhner, B. Iung "Formalisation of a new prognosis model for supporting proactive maintenance implementation on industrial system", *Reliability Engineering & System Safety*, vol. 93, no. 2, pp. 234-253, 2008.
- [20] D.A. Tobon-Mejia, K. Medjaher,N. Zerhouni, "The ISO 13381-1 standard's failure prognostics process through an example", *IEEE Prognostics and Health Management Conference (PHM'10)*, pp. 1-12, Jan. 2010.
- [21] D. Gucik-Derigny, "Contribution au pronostic des systèmes à base de modèles : théorie et application", *l'Université Paul Cézanne Aix-Marseille III*, Doctoral dissertation, 2011.
- [22] J. Lee, F. Wu, W. Zhao, M. Ghaffari, L. Liao, D. Siegel, "Prognostics and health management design for rotary machinery systems - Reviews, methodology and applications", *Mechanical Systems and Signal Processing*, vol. 42, no. 1, pp. 314-334, 2014.

- 
- [23] R.K. Singleton, E.G. Strangas, S. Aviyente, "Extended Kalman Filtering for Remaining Useful Life Estimation of Bearings", *IEEE Transactions on Industrial Electronics* 2015.
- [24] D.E. Adams, M. Nataraju, "A nonlinear dynamical systems framework for structural diagnosis and prognosis", *International Journal of Engineering Science*, vol. 40, no. 17, pp. 1919-1941, 2002.
- [25] C.J. Li, H. Lee, H. "Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics", *Mechanical systems and signal processing*, vol. 19, no. 4, pp. 836-846, 2005.
- [26] J. Luo, M. Namburu, K. Pattipati, L. Qiao, M. Kawamoto and S. Chigusa, "Model-Based Prognostic Techniques" , *AUTOTESTCON 2003, Proceedings of IEEE Systems Readiness Technology Conference*, pp. 330-340, 2003.
- [27] M.J. Roemer and G.J. Kacprzynski, M. Kawamoto and S. Chigusa, "Advanced diagnostics and prognostics for gas turbine engine risk assessment" , *IEEE, Aerospace Conference Proceedings*, pp. 345-353, 2000.
- [28] A. Ray, and S. Tangirala, "Stochastic modeling of fatigue crack dynamics for on-line failure prognostics", *IEEE Transactions on Control Systems Technology*, vol. 4, no. 4, pp. 443-451, 1996.
- [29] A. Dasgupta and M. Pecht, "Material failure mechanisms and damage models", *IEEE Transactions on Reliability* , vol. 40, no. 5, pp. 531-536, 1991.
- [30] E. Myotyrri, U. Pulkkinen, K. Simola, "Application of stochastic filtering for lifetime prediction", *Reliability Engineering & System Safety*, vol. 91, no. 2, pp. 200-208, 2006.
- [31] M.A. Djeziri, B. Ananou, M. Ouladsine, "Data driven and model based fault prognosis applied to a mechatronic system", *IEEE Fourth International Conference on Power Engineering, Energy and Electrical Drives (POWERENG)*, pp. 534-539, May 2013.
- [32] A.K. Garga, K.T. McClintic, R.L. Campbell, C.C. Yang, M.S. Lebold, T.A. Hay and C.S. Byington, "Hybrid reasoning for prognostic learning in CBM systems", *IEEE Proceedings in Aerospace Conference*, vol. 6, pp. 2957-2969, 2001.
- [33] S. Kumar, M. Torres, Y.C. Chan, M. Pecht, "A hybrid prognostics methodology for electronic products", *IEEE International Joint Conference on Neural Networks (IJCNN)*, pp. 3479-3485, Jun. 2008.
- [34] H. Zhang, R. Kang, M. Pecht, "A hybrid prognostics and health management approach for condition-based maintenance", *IEEE International Conference on Industrial Engineering and Engineering Management*, pp. 1165-1169, Dec. 2009.
- [35] L. Liao, F. Kottig, "Review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction", *IEEE Transactions on Reliability*, vol. 63, no. 1, pp. 191-207, 2014.

- [36] A. Majidian and M.H. Saidi, "Comparison of fuzzy logic and neural network in life prediction of boiler tubes", *International Journal of Fatigue*, vol. 29, no. 3, pp. 489-498, 2007.
- [37] T. Biagetti and E. Sciubba, "Automatic diagnostics and prognostics of energy conversion processes via knowledge-based systems", *Energy*, vol. 29, no. 12, pp. 2553-2572, 2004.
- [38] L. Shimanek, "Battery prognostics", *EMPFasis*, vol. 12, pp. 1-2, 2003.
- [39] E. Feng, H. Yang and M. Rao, "Fuzzy expert system for real-time process condition monitoring and incident prevention", *Expert Systems with Applications*, vol. 15, pp. 383-390, 1998.
- [40] N. Gebraeel, M. Lawley, R. Liu, and V. Parmeshwaran, "Residual life predictions from vibration-based degradation signals : a neural network approach", *IEEE Transactions on Industrial Electronics*, vol. 51, no. 3, pp. 694-700, 2004.
- [41] F. Peysson, M. Ouladsine, R. Outbib, J.B. Leger, O. Myx, and C. Allemand, "A Generic Prognostic Methodology Using Damage Trajectory Models", *IEEE Transactions on Reliability*, vol. 58, no. 2, pp. 277-285, 2009.
- [42] R. Huang, L. Xi, X. Li, C. Richard Liu, H. Qiu and J. Lee, "Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods", *Mechanical Systems and Signal Processing*, vol. 21, no. 1, pp. 193-207, 2007.
- [43] A.P. Vassilopoulos, E.F. Georgopoulos and V. Dionysopoulos, "Artificial neural networks in spectrum fatigue life prediction of composite materials", *International Journal of Fatigue*, vol. 29, no. 1, pp. 20-29, 2007.
- [44] G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess and B. Wu, "Intelligent Fault Diagnosis and Prognosis for Engineering Systems", *John Wiley & Sons, Inc.*, Hoboken, New Jersey, 2006.
- [45] T. Khawaja, G. Vachtsevanos and B. Wu, "Reasoning about uncertainty in prognosis : a confidence prediction neural network approach", *In Fuzzy Information Processing Society, NAFIPS 2005*, Annual Meeting of the North American, pp. 7-12, 2005.
- [46] M.A. Djeziri, H. Toubakh, M. Ouladsine, "Fault prognosis based on fault reconstruction : Application to a mechatronic system", *2013 IEEE 3rd International Conference on Systems and Control (ICSC)*, pp. 383-388, October, 2013.
- [47] J. Yan, M. Koc and J. Lee, "A prognostic algorithm for machine performance assessment and its application", *Production Planning & Control*, vol. 15, no. 8, pp. 796-801, 2004.

- 
- [48] W. Wu, J. Hu and J. Zhang, "Prognostics of machine health condition using an improved ARIMA-based prediction method", *2nd IEEE Conference on Industrial Electronics and Applications (ICIEA 2007)*, pp. 1062-1067, May. 2007.
- [49] J. Lee, J. Ni, D. Djurdjanovic, H. Qiu and H. Liao, "Intelligent prognostics tools and e-maintenance", *Computers in industry*, vol. 57, no. 6, pp. 476-489, 2006.
- [50] J.M. Van Noortwijk, "A survey of the application of gamma processes in maintenance", *Reliability Engineering & System Safety*, vol. 94, no. 1, pp. 2-21, 2009.
- [51] V. Bagdonavicius and M.S. Nikulin, "Estimation in degradation models with explanatory variables", *Lifetime Data Analysis*, vol. 7, no. 1, pp. 85-103, 2001.
- [52] A. Lehmann, "Joint modeling of degradation and failure time data", *Journal of Statistical Planning and Inference*, vol. 139, no. 5, pp. 1693-1706, 2009.
- [53] X.S. Si, W. Wang, C.H. Hu and D.H. Zhou, "Remaining useful life estimation : A review on the statistical data driven approaches", *European Journal of Operational Research*, vol. 213, no. 1, pp. 1-14, 2011.
- [54] D.R. Cox and H.D. Miller, "The theory of stochastic processes", *CRC Press* vol. 134, 1977.
- [55] K. Le Son, M. Fouladirad, A. Barros, E. Levrat & B. Iung, "Remaining useful life estimation based on stochastic deterioration models : A comparative study", *Reliability Engineering & System Safety*, vol. 112, pp. 165-175, 2013.
- [56] S.T. Tseng, J. Tang & I.H. Ku, "Determination of burn-in parameters and residual life for highly reliable products", *Naval Research Logistics (NRL)*, vol. 50, no. 1, pp. 1-14, 2003.
- [57] S.T. Tseng & C.Y. Peng, "Stochastic diffusion modeling of degradation data", *Journal of Data Science*, vol. 5, no. 3, pp. 315-333, 2007.
- [58] X. Wang, "Wiener processes with random effects for degradation data", *Journal of Multivariate Analysis*, vol. 101, no. 2, pp. 340-351, 2010.
- [59] C. Park & W.J. Padgett, "Accelerated degradation models for failure based on geometric Brownian motion and gamma processes", *Lifetime Data Analysis*, vol. 11, no. 4, pp. 511-527, 2005.
- [60] W. Wang, M. Carr, W. Xu & K. Kobbacy, "A model for residual life prediction based on Brownian motion with an adaptive drift", *Microelectronics Reliability*, vol. 51, vol. 2, pp. 285-293, 2011.
- [61] M. Abdel-Hameed, "A gamma wear process", *IEEE Transactions on Reliability*, vol. 24, no. 2, pp. 152-153, 1975.

- [62] E. Çinlar, E. Osman & Z.P. Bazant, "Stochastic process for extrapolating concrete creep", *Journal of the Engineering Mechanics Division*, vol. 103, no. 6, pp. 1069-1088, 1977.
- [63] J. Lawless & M. Crowder, "Covariates and random effects in a gamma process model with application to degradation and failure", *Lifetime Data Analysis*, vol. 10, no. 3, pp. 213-227, 2004.
- [64] D.M. Frangopol, M.J. Kallen & J.M. van Noortwijk, "Probabilistic models for life cycle performance of deteriorating structures : review and future directions", *Progress in Structural Engineering and Materials*, vol. 6, no. 4, pp. 197-212, 2004.
- [65] J.D. Bakker & J.M. van Noortwijk, "Inspection validation model for life-cycle analysis", *Bridge maintenance, safety, management and cost, proceedings of the second international conference on bridge maintenance, safety and management (IABMAS)*, Kyoto, Japan, pp. 18-22, Oct. 2004.
- [66] M. Abdel-Hameed, "Inspection and maintenance policies of devices subject to deterioration", *Advances in Applied Probability*, pp. 917-931, 1987.
- [67] M.B. Kong & K.S. Park, "Optimal replacement of an item subject to cumulative damage under periodic inspections", *Microelectronics Reliability*, vol. 37, no. 3, pp. 467-472, 1997.
- [68] L. Dieulle, C. Bérenguer, A. Grall & M. Roussignol, "Sequential condition-based maintenance scheduling for a deteriorating system", *European Journal of operational research*, vol. 150, no. 2, pp. 451-461, 2003.
- [69] A. Grall, L. Dieulle, C. Bérenguer & M. Roussignol, "Asymptotic failure rate of a continuously monitored system", *Reliability Engineering & System Safety*, vol. 91, no. 2, pp. 126-130, 2006.
- [70] M.D. Pandey, X.X. Yuan & J.M. van Noortwijk, "The influence of temporal uncertainty of deterioration on life-cycle management of structures", *Structure and Infrastructure Engineering*, vol. 5, no. 2, pp. 145-156, 2009.
- [71] D. R. Cox, "Regression Models and Life-Tables", *Journal of the Royal Statistical Society, Series B (Methodological)*, vol. 34, no. 2, pp. 187-220, 1972.
- [72] D. Banjevic, "Remaining useful life in theory and practice", *Metrika*, vol. 69, no.2-3, pp. 337-349, 2009.
- [73] V. Makis, A.K. Jardine, "Optimal replacement in the proportional hazards model", *Infor* , vol. 30, no. 1, pp. 172-183, 1992.
- [74] P.J. Vlok, J.L. Coetzee, D. Banjevic, A.K.S Jardine, V. Makis, "Optimal component replacement decisions using vibration monitoring and the proportional-hazards model", *Journal of the operational research society* , pp. 193-202, 2002.

- 
- [75] X. Zhao, M. Fouladirad, C. Bérenguer, L. Bordes, "Condition-based inspection/replacement policies for non-monotone deteriorating systems with environmental covariates", *Reliability Engineering & System Safety*, vol. 95, no. 8, pp. 921-934, 2010.
- [76] A.K.S Jardine, D. Banjevic, N. Montgomery, A. Pak, "Repairable system reliability : Recent developments in CBM optimization", *International Journal of Performability Engineering*, vol. 4, no. 3, pp. 205-214, 2008.
- [77] A. Zuashkiani, D. Banjevic, A.K. Jardine, "Incorporating expert knowledge when estimating parameters of the proportional hazards model", *IEEE in Reliability and Maintainability Symposium (RAMS'06)*, pp. 402-408, Jan. 2006.
- [78] S. Ferreiro, A. Arnaiz, B. Sierra, I. Irigoien, "Application of Bayesian networks in prognostics for a new Integrated Vehicle Health Management concept", *Expert Systems with Applications*, vol. 39, no. 7, pp. 6402-6418, 2012.
- [79] Q. Miao, V. Makis, "Condition monitoring and classification of rotating machinery using wavelets and hidden Markov models", *Mechanical Systems and Signal Processing*, vol. 21, no. 2, pp. 840-855, 2007.
- [80] J. Yu, "Health condition monitoring of machines based on hidden markov model and contribution analysis", *IEEE Transactions on Instrumentation and Measurement*, vol. 61, no. 8, pp. 2200-2211, 2012.
- [81] E. Bechhoefer, A. Bernhard, D. He, P. Banerjee, "Use of hidden semi-Markov models in the prognostics of shaft failure", *Annual forum proceedings - American Helicopter Society*, pp. 1330-1335, 2006.
- [82] M. Dong, D. He, "A segmental hidden semi-Markov model (HSMM)-based diagnostics and prognostics framework and methodology", *Mechanical Systems and Signal Processing*, vol. 21, no. 5, pp. 2248-2266, 2007.
- [83] A.H. Christer, W. Wang, J. Sharp, "A state space condition monitoring model for furnace erosion prediction and replacement", *European Journal of Operational Research*, vol. 101, no. 1, pp. 1-14, 1997.
- [84] R.K. Singleton, E.G. Strangas, S. Aviyente, "Extended Kalman Filtering for Remaining Useful Life Estimation of Bearings", *IEEE Transactions on Industrial Electronics*, 2014.
- [85] C.K.R. Lim, D. Mba, "Switching Kalman filter for failure prognostic", *Mechanical Systems and Signal Processing*, vol. 52, pp. 426-435, 2015.
- [86] M. Orchard, B. Wu, G. Vachtsevanos, "A particle filtering framework for failure prognosis", *World Tribology Congress III, American Society of Mechanical Engineers*, pp. 883-884, Jan. 2005.

- [87] F. Cadini, E. Zio, D. Avram, "Model-based Monte Carlo state estimation for condition-based component replacement", *Reliability Engineering & System Safety*, vol. 94, no. 3, pp. 752-758, 2009.
- [88] J. Sun, H. Zuo, W. Wang, M.G. Pecht, "Prognostics uncertainty reduction by fusing on-line monitoring data based on a state-space-based degradation model", *Mechanical Systems and Signal Processing*, vol. 45, no. 2, pp. 396-407, 2014.
- [89] A. Boubezoul, "Système d'aide au diagnostic par apprentissage : application aux systèmes microélectroniques", *Doctoral dissertation, Université Paul Cézanne, Marseille, France*, 2008.
- [90] Y. Peng, D. Ming, J.Z. Ming, "Current status of machine prognostics in condition-based maintenance : a review", *The International Journal of Advanced Manufacturing Technology*, vol. 50, no. 1-4, pp. 297-313, 2010.
- [91] G.J. Kacprzyński, "Sensor/model fusion for adaptive prognosis of structural corrosion damage", *Impact Technologies LLC Rochester NY*, 2006.
- [92] S. Kumar, M. Torres, Y.C. Chan, M. Petch, "A hybrid prognostics methodology for electronic products", *IEEE World Congress on Computational Intelligence*, pp. 3479-3485, 2008.
- [93] S. Mohanty, A. Chattopadhyay, P. Peralta, S. Das, C. Willhauck, "Fatigue Life Prediction Using Multivariate Gaussian Process", *49th AIAA Structuresn Structural Dynamics and Materials Conference*, 2008.
- [94] T. Brotherton, G. Jahns, J. Jacobs, D. Wroblewski, "Prognosis of faults in gas turbine engines", *IEEE in Aerospace Conference Proceedings*, vol. 6, pp. 163-171, 2000.
- [95] A.K. Garga, K.T. McClintic, R.L. Campbell, C.C Yang, M.S. Lebold, T. Hay, C.S. Byington, "Hybrid reasoning for prognostic learning in CBM systems", *IEEE Proceedings in Aerospace Conference*, vol. 6, pp. 2957-2969, 2001.
- [96] W.Q. Wang, M.F. Golnaraghi, F. Ismail, "Prognosis of machine health condition using neuro-fuzzy systems", *Mechanical Systems and Signal Processing*, vol. 18, no. 4, pp. 813-831, 2004.
- [97] J. Yan, J. Lee, "A hybrid method for on-line performance assessment and life prediction in drilling operations", *IEEE International Conference on Automation and Logistics*, pp. 2500-2505, Aug. 2007.
- [98] Y. Peng, D. Ming, "A hybrid approach of HMM and grey model for age-dependent health prediction of engineering assets", *Expert Systems with Applications*, vol. 38, no. 10, pp. 12946-12953, 2011.
- [99] I. Jolliffe, "Principal component analysis", *John Wiley & Sons, Ltd.*, 2005.

- 
- [100] B. Schölkopf, A. Smola, K.R Müller, "Kernel principal component analysis", *Artificial Neural Networks - ICANN'97, Springer Berlin Heidelberg*, pp. 583-588, 1997
- [101] P. Geladi, B.R. Kowalski, "Partial least-squares regression : a tutorial" *Analytica chimica acta*, vol. 185, pp. 1-17, 1986.
- [102] A. Hyvärinen, J. Karhunen, E. Oja, E. "Independent component analysis", *John Wiley & Sons*, vol. 46, 2004.
- [103] J.B. Tenenbaum, V. De Silva, J.C. Langford, "A global geometric framework for nonlinear dimensionality reduction", *Science*, vol. 290, no. 5500, pp. 2319-2323, 2000.
- [104] L.J.P. Van der Maaten, E.O. Postma, H.J. Van den Herik, "Dimensionality reduction : A comparative review", *Journal of Machine Learning Research*, vol. 10, pp. 1-41, 2009.
- [105] J. Lawless, M. Crowder, "Covariates and Random Effects in a Gamma Process Model with Application to Degradation and Failure", *Lifetime Data Analysis*, vol. 10, no. 3, pp. 213-227, 2004.
- [106] S.T. Tseng, C.Y. Peng, "Stochastic diffusion modeling of degradation data", *Journal of Data Science*, vol. 5, no. 3, pp. 315-333, 2007.
- [107] J. Bakker, J. van. Noordwijk, "Inspection validation model for life-cycle analysis", *Second international conference on bridge maintenance, safety and management*, Kyoto, Japan, pp. 18-22, 2004.
- [108] S.J. Qin, "Statistical process monitoring : basics and beyond", *Journal of chemometrics*, vol. 17, no. 8-9, pp. 480-502, 2003.
- [109] C.F. Alcala, S.J. Qin, "Reconstruction-based contribution for process monitoring", *Automatica*, vol. 45, no. 7, pp. 1593-1600, 2009.
- [110] G. Li, S.J. Qin, Y. Ji, D. Zhou, "Reconstruction based fault prognosis for continuous processes", *Control Engineering Practice*, vol. 18, no. 10, pp. 1211-1219, 2010.
- [111] T. Benkedjouh, K. Medjaher, N. Zerhouni, S. Rechak, "Remaining useful life estimation based on nonlinear feature reduction and support vector regression", *Engineering Applications of Artificial Intelligence*, vol. 26, no. 7, pp. 1751-1760, 2013.
- [112] T. Wang, J. Yu, D. Siegel, J. Lee, "A similarity-based prognostics approach for remaining useful life estimation of engineered systems", *IEEE International Conference on Prognostics and Health Management (PHM 2008)*, pp. 1-6, Oct. 2008.
- [113] J. Yan, M. Koc, J. Lee, "A prognostic algorithm for machine performance assessment and its application", *Production Planning & Control*, vol. 15, no. 8, pp. 796-801, 2004.
- [114] N. Williard, W. He, M. Osterman, M. Pecht, "Comparative analysis of features for determining state of health in lithium-ion batteries", *International Journal of PHM*, vol. 4, pp. 1-7, 2013.

- [115] V. Sotiris, M. Pecht, "Support vector prognostics analysis of electronic products and systems", *The AAAI conference on artificial intelligence*, Nov. 2007.
- [116] J.K Kimotho, W. Sextro, "An approach for feature extraction and selection from non-trending data for machinery prognosis", *2nd European Conference of the Prognostics and Health Management Society (PHME14), Nantes, France*, pp. 215-222, 2014.
- [117] D. Galar, U. Kumar, J. Lee, W. Zhao, "Remaining useful life estimation using time trajectory tracking and support vector machines", *Journal of Physics : Conference Series*, vol. 364, no. 1, May 2012.
- [118] D. Di Maio, J. Hu, P. Tse, M. Pecht, K. Tsui, E. Zio, "Ensemble-approaches for clustering health status of oil sand pumps" *Expert Systems with Applications*, vol. 39, no. 5, pp. 4847-4859, 2012.
- [119] P. Nomikos, J.F. Macgregor, "Multivariate SPC Charts for Monitoring Batch Processes", *Technometrics*, vol. 37, no. 1, pp. 41-58, Feb. 1995.
- [120] J.M. Lee, C. Yoo, I.B. Lee, "Fault detection of batch processes using multiway kernel principal component analysis", *Computers & Chemical Engineering*, vol.28, no. 9, pp. 1837-1847, 2004.
- [121] H.H. Yue, S.J. Qin, "Reconstruction-based fault identification using a combined index", *Industrial & Engineering Chemistry Research*, vol. 40, no. 20, pp. 4403-4414, 2001.
- [122] Y. Zhang, "Improved Methods in Statistical and First Principles Modeling", *The University of Texas at Austin, PhD dissertation*, 2008.
- [123] A. Thioullien, M. Ouladsine, J. Pinaton, "Application of Principal Components Analysis to improve fault detection and diagnosis on semiconductor manufacturing equipment", *European Control Conference (ECC)*, Zurich, Switzerland, pp. 1445-1500, 2013.
- [124] A. Thioullien, M. Ouladsine, J. Pinaton, "A Survey of Health Indicators and Data-Driven Prognosis in Semiconductor Manufacturing Process", *8th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes (SAFEPROCESS)*, Mexico city, Mexico, vol.8, pp. 19-24, 2012.
- [125] G.A. Cherry, S.J. Qin, "Multiblock principal component analysis based on a combined index for semiconductor fault detection and diagnosis", *IEEE Transactions on Semiconductor Manufacturing*, vol. 19, no. 2, pp. 159-172, 2006.
- [126] S.J. Zhao, J. Zhang, Y.M. Xu, "Performance monitoring of processes with multiple operating modes through multiple PLS models", *Journal of Process Control*, vol. 16, no. 7, pp. 763-772, 2006.

- 
- [127] D.A. White, D. Boning, S.W. Butler, G.G. Barna, "Spatial characterization of wafer state using principal component analysis of optical emission spectra in plasma etch", *IEEE Transactions on Semiconductor Manufacturing*, vol. 10, no. 1, pp. 52-61, 1997.
- [128] B.P. Leao, T. Yoneyama, G.C. Rocha, K.T. Fitzgibbon, "Prognostics performance metrics and their relation to requirements, design, verification and cost-benefit", *International Conference on Prognostics and Health Management (PHM08)*, pp. 1-8, 2008.
- [129] T. Wang, J. Lee, "On Performance Evaluation of Prognostics Algorithms", *Machinery Failure Prevention Technology*, 2009.
- [130] A. Saxena, J. Celaya, E. Balaban, B. Saha, S. Saha, K. Goebel, "Metrics for evaluating performance of prognostic techniques", *International Conference on Prognostics and Health Management (PHM08)*, pp. 1-17, 2008.
- [131] A. Saxena, J. Celaya, B. Saha, S. Saha, K. Goebel, "On applying the prognostic performance metrics", *Annual Conference of the Prognostics and Health Management Society*, 2009.
- [132] B. Mnassri, E. M. E. Adel, and M. Ouladsine, "Generalization and analysis of sufficient conditions for PCA-based fault detectability and isolability", *Annual Reviews in Control*, vol. 37, no. 1, pp. 154-162, 2013.
- [133] R. Engle, "Dynamic Conditional Correlation - A Simple Class Of Multivariate Garch Models", *Journal of Business and Economic Statistics*, vol. 20, pp. 339-350, 2000.
- [134] N.R. Draper, H. Smith, E. Pownell, "Applied regression analysis", *New York : Wiley*, vol. 3, 1966.
- [135] K. Schittkowski, "Numerical data fitting in dynamical systems : a practical introduction with applications and software", *Springer Science & Business Media*, vol. 77, 2002.
- [136] N. Meade, T. Islam, "Prediction intervals for growth curve forecasts", *Journal of Forecasting*, vol. 14, no. 5, pp. 413-430, 1995.
- [137] D. Galar, U. Kumar, J. Lee, W. Zhao, "Remaining useful life estimation using time trajectory tracking and support vector machines" *Journal of Physics : Conference Series*, vol. 364, no. 1, May 2012.
- [138] F. Di Maio, J. Hu, P. Tse, M. Pecht, K. Tsui, E. Zio, E. "Ensemble-approaches for clustering health status of oil sand pumps", *Expert Systems with Applications*, vol. 39, no. 5, pp. 4847-4859, 2012.
- [139] N.E. Huang, Z. Shen, S.R. Long, M.C. Wu, H.H. Shih, Q. Zheng, H.H. Liu, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis", *Proceedings of the Royal Society of London A : Mathematical, Physical and Engineering Sciences*, vol. 454, no. 1971, pp. 903-995, Mar. 1998.

- [140] A.V. Oppenheim, R.W. Schaffer, J.R. Buck, "Discrete-time signal processing", *Englewood Cliffs : Prentice-hall*, vol. 2, 1989.
- [141] S.G. Mallat, "A theory for multiresolution signal decomposition : the wavelet representation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674-693, 1989.
- [142] S.G. Mallat, "A wavelet tour of signal processing", *Academic press*, 1999.
- [143] T. Wang, J. Yu, D. Siegel, J. Lee, "A similarity-based prognostics approach for remaining useful life estimation of engineered systems", *IEEE International Conference on Prognostics and Health Management (PHM 2008)*, pp. 1-6, Oct. 2008.
- [144] D. Yu, J. Cheng, Y. Yang, "Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings", *Mechanical systems and signal processing*, vol. 19, no. 2, pp. 259-270, 2005.
- [145] J. Altmann, J. Mathew, "Multiple band-pass autoregressive demodulation for rolling-element bearing fault diagnosis", *Mechanical systems and signal processing*, vol. 15, no. 5, pp. 963-977, 2001.
- [146] J. Lin, M.J. Zuo, "Gearbox fault diagnosis using adaptive wavelet filter", *Mechanical systems and signal processing*, no. 17, vol. 6, pp. 1259-1269, 2003.
- [147] O. Saarela, J.E. Hulsund, A. Taipale, M. Hegle, "Remaining Useful Life Estimation for Air Filters at a Nuclear Power Plant", *European Conference of the PHM Society 2014 Proceedings*, pp. 75-81, 2014.
- [148] K. Le Son, M. Fouladirad, A. Barros, E. Levrat, B. Iung, "Remaining useful life estimation based on stochastic deterioration models : A comparative study", *Reliability Engineering and System Safety*, 2012.
- [149] Z. Xi, R. Jing, P. Wang, C. Hu, "A copula-based sampling method for data-driven prognostics", *Reliability Engineering and System Safety*, pp. 72-82, 2014.
- [150] C. Chen, D. Brown, C. Sconyers, B. Zhang, G. Vachtsevanos, M. E. Orchard, "An integrated architecture for fault diagnosis and failure prognosis of complex engineering systems", *Expert Systems with Applications*, vol. 39, no. 10, pp. 9031-9040, 2012.
- [151] K. Liu, N. Gebraeel, J. Shi, "A data-level fusion model for developing composite health indices for degradation modeling and prognostic analysis", *IEEE Transactions on Automation Science and Engineering*, vol. 10, no. 3, pp. 652-664, 2013.
- [152] E. Langford, "Quartiles in elementary statistics", *Journal of Statistics Education*, vol. 14, no.3, 2006.
- [153] L. Fenton, "The sum of log-normal probability distributions in scatter transmission systems", *IRE Transactions on Communications Systems*, vol. 8, no. 1, pp. 57-67, 1960.

- 
- [154] T.B.L. Nguyen, M. Djeziri, B. Ananou, M. Ouladsine, and J. Pinaton, "Fault prognosis for discrete manufacturing processes", *19th World Congress of the International Federation of Automatic Control (IFAC-WC)*, Cape Town, South Africa, pp. 8066-8072, 2014.
- [155] T. B. L. Nguyen, M. Djeziri, B. Ananou, M. Ouladsine, and J. Pinaton, "Fault prognosis with stochastic modelling on critical points of discrete processes", *2nd European Conference of the Prognostics and Health Management Society (PHME14)*, Nantes, France, pp. 346-353, 2014.
- [156] T. B. L. Nguyen, M. Djeziri, B. Ananou, M. Ouladsine, and J. Pinaton, "Health index extraction methods for batch processes in semiconductor manufacturing", *IEEE Transactions on Semiconductor Manufacturing*, vol. 28, no. 3, pp. 306-317, 2015.
- [157] T. B. L. Nguyen, M. Djeziri, B. Ananou, M. Ouladsine, and J. Pinaton, "Degradation modelling with operating mode changes", *2015 IEEE International Conference on Prognostics and Health Management (PHM)*, Texas, USA, pp. ,2015.
- [158] T. B. L. Nguyen, M. Djeziri, B. Ananou, M. Ouladsine, and J. Pinaton, "Remaining Useful Life estimation for noisy degradation trends", *9th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS'15)*, Paris, France, pp. , 2015.
- [159] M. Melhem, B. Ananou, M. Djeziri, M. Ouladsine, and J. Pinaton, "Prediction of the Wafer Quality with Respect to the Production Equipments Data", *9th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes(SAFEPROCESS'15)*, Paris, France, pp. , 2015.

