

الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR-ANNABA UNIVERSITY

UNIVERSITÉ BADJI MOKHTAR-ANNABA



جامعة باجي مختار - عنابة

Année 2016/2017

Faculté des Sciences de l'Ingéniorat
Département d'électrotechnique

THESE

Présenté en vue de l'obtention du diplôme de **Doctorat**

DIAGNOSTIC DES SYSTÈMES NON LINÉAIRES PAR ANALYSE STATISTIQUE MULTIVARIÉE

Option : **Commande Electrique**

Par : **AOUABDI Salim**

DIRECTEUR DE THESE :

TAIBI Mahmoud

Professeur

Université de Annaba

DEVANT LE JURY:

PRÉSIDENT :

LABAR Hocine

Professeur

Université de Annaba

EXAMINATEURS :

Taleb Ahmed Abdelmalik

Professeur

Université de Valenciennes France

Lachouri Abderezak

Professeur

Université de Skikda

Louchene Ahmed

Professeur

Université de Batna

Debbache Nasreddine

Professeur

Université de Annaba

ملخص:

يمكن تعريف تشخيص أنظمة التشغيل باعتباره سلسلة من العمليات التي تم تصميمها لكشف و تحديد موقع في النظام و الأخطاء الداخلية (المنهجية نفسها) , أخطاء خارجية (المحرك و الأجهزة) و سائل وظيفية عملية غير طبيعية و تميز اساليب التشغيل و الأخطاء و أوضاع التشغيل من بين الاساليب المستخدمة و عادة ما تميز الطرق التي تعتمد على تحليل البيانات التي تم جمعها على الأنظمة على سبيل المثال التعرف على انماط الاشكال. لتحسين الطرق العملية يجب ان تتوفر أحسن الو سائل العملية للمراقبة و لتحسين سلوك الأنظمة يجب علينا ان ندرك في كل لحظة حالة تشغيل النظام و نكون قادرين على تميز الحالات العادية من تلك الغير عادية وفي بعض الحالات يجب علينا من الضروري التنبؤ بتطور حالة النظام وخلق وسائط متغيرة الاحوال للعملية و الاساليب. ومن الضروري بالإضافة الى ذلك فهم وحل المشاكل المتصلة بالمعلوماتية الطرق تحتاج الى معلومات متسقة فيما بينها لإدارة عملياتها كجزء من النهج القائم. و الهدف من ذلك يمكن في خلق افضل النماذج لأنظمة التحكم بغرض وضع افضل نماذج تشخيصية قوية وفعالة مع الاخذ بعين الاعتبار عدم اليقين النموذجي و عدم الدقة المعرفية في بعض الاحيان بشكل عام. التعقيدات الالية المشاركة على سبيل المثال الحركة الغير خطية , تفاوت المعلومات فيما بينها في الوقت المناسب و أخطاء القياس. كل هذا يتطلب منا تطوير و استخدام تقنيات جد متطورة وأليات حديثة لوضع استراتيجية تشخيصية بحتة في الوقت المناسب. و لهذا يجدر علينا استخدام تقنيات معالجة الاشارة و البيانات بهدف تطوير استراتيجيات التشخيص. و هكذا تقنيات تحديد النظام باستخدام القياسات المتاحة لثم تحليلها و دراستها. علينا أن نذكر أن تحليل المكونات الرئيسية هو تحليل مكون ذو طريقة خطية في حين أن معظم الأنظمة الفيزيائية لديها نهج غير خطي في الواقع و لأجل ذلك هناك دافع من الجهود لتوسيع نطاق التحليل في اطار السلوك الغير خطي للنظام.

كلمات البحث: رصد أجهزة الاستشعار, تحليل المكونات الرئيسية, احصاءات متعددة المتغيرات

Abstract

The exploitation functional systems diagnosis could be defined as series of operation which has an aim to detect and pinpoint in the system: process internal failing instrumentation and sensors external defaults, and abnormal functional modes and to characterize the operational modes and failings. Among the methods use, we distinguish generally the methods using parametric model that describe the system behavior to be monitor (methods using analytical model) which use only taking data of the systems. Such as forms recognition. The processes operation optimization must have a good system process operations monitoring to improve the systems operations we must know at every instant the functional status of the system and be able to discriminate the abnormal states from the normal ones. In certain situation, it is even necessary to predict the status evolution of the systems and to suggest prognostic of operation and modes. It is very important to solve the problem linked to information: the operation needs coherences information to manage the process. Even in mathematical model approach it is necessary to take into account the model imprecision as well as the development of robust diagnosis system. The complexity game setting: (non-linearity, time variables parameterized and the measurement errors) impose the development of advance technical of automation and functional diagnosis in real time. For this aim we use data and signals processing to get a good systems diagnostic. The systems technical are identification which use available measurements of the process such as (Principal component analysis PCA) are developed.

The PCA is linear method used for physical systems that are usually nonlinear. For the non-linear systems nowadays we tend to use soft computing methods such as Neuronal network, Principal curves, and RBF... etc.

It will be also necessary to develop new methods using nonlinear NLPCA mathematical models and to apply to them.

Key words: Monitoring of sensors, Principal component analysis (PCA) and (NLPCA), Multivariate statistics and ANN.

Résumé

Le diagnostic de fonctionnement de systèmes peut être défini comme une suite d'opérations qui a pour objet de détecter et de localiser dans un système, les défauts internes (processus lui-même), les défauts externes (actionneur, instrumentation), les modes de fonctionnement anormaux et de caractériser ces défauts ou modes de fonctionnement. Parmi les méthodes employées, on distingue généralement celles utilisant un modèle paramétrique décrivant le comportement du système à surveiller (méthodes à base de modèle analytique) de celles qui ne s'appuient que sur l'analyse des données prélevées sur les systèmes comme, par exemple, la reconnaissance de formes. L'optimisation des processus et leur fonctionnement passe donc par une mise en place d'un système de surveillance du fonctionnement de ces processus. En effet, pour améliorer la conduite d'un système, il faut connaître, à chaque instant, l'état de fonctionnement de ce système et pouvoir discriminer états normaux et anormaux. Dans certaines situations, il est même nécessaire de prévoir l'évolution de l'état du système et de proposer un pronostic d'évolution des modes de fonctionnement. De plus, il est important de résoudre le problème lié à l'information : l'exploitant a besoin d'informations cohérentes pour gérer son processus. Dans le cadre d'une approche à base de modèle, l'objectif est mieux maîtriser la modélisation des systèmes (y compris les limites de modélisation) pour développer des approches de diagnostic robustes vis-à-vis des incertitudes de modélisation et des imprécisions de connaissance de façon plus générale. La complexité des mécanismes mis en jeu (les cinétiques non linéaires, les paramètres variant dans le temps, l'absence de mesures fiables) impose le développement et l'utilisation de techniques avancées de l'automatique pour développer une stratégie de diagnostic de fonctionnement en temps réel. Il est question donc d'utiliser des techniques de traitement de données pour développer des stratégies de diagnostic des systèmes. Ainsi des techniques d'identification des systèmes qui utilisent les mesures disponibles sur le processus telles que l'analyse en composantes principales (ACP) sont à développer. Il faut rappeler que l'analyse en composantes principales est une méthode linéaire, alors que la plupart des systèmes physiques ont des comportements non linéaires. Ceci a motivé un certain nombre de travaux pour étendre la portée de l'analyse dans un cadre non linéaire.

Mot Clés : Surveillance des capteurs, Analyse en composantes principales (ACP) et (ACP NL), Statistique multivariée et ANN.

Dédicaces

Je dédie ce modeste travail :

À mes chers parents

À ma femme et mes petits **Aymene et Oussama**

À mes frères et unique sœur

À toute ma grande famille

À tous mes amis

Aux chercheurs de l'unité de recherche en matériaux avancées URMA-Annaba

Aux enseignants de l'Université de Badji Mokhtar Annaba et tout particulièrement aux enseignants de département d'électrotechnique.

A monsieur le chef de Structure Electricité Instrumentation département de Ferial _Annaba, pour m'avoir aidé dans la réalisation de mes stages. Je lui suis profondément reconnaissant de m'avoir fait bénéficier de son expérience et de ses compétences tout au long de mes stages qui ont beaucoup compté dans ma formation.

Remerciements

Le travail présenté dans cette thèse a été réalisé au sein du Département d'électrotechnique et électromécanique, faculté des sciences de l'ingénierie, *Université Badji Mokhtar Annaba*.

Je tiens à remercier vivement Monsieur le Professeur **TAIBI Mahmoud**, Directeur de cette thèse, pour m'avoir encadré, tout en lui exprimant ma sincère gratitude pour son aide, sa disponibilité et ses précieux conseils qui m'ont été d'une grande utilité dans l'avancement de ce travail.

Mes remerciements s'adressent également à Monsieur **LABAR Hocine** pour avoir accepté d'examiner ce travail en tant que Président du Jury.

Je remercie, par la même occasion, Messieurs les Professeurs : **DEBBACHE Nasr Eddine**, **TALEB-AHMED Abdelmalik**, **LACHOURI Abderezzak** et **LOUCHENE Ahmed** qui ont accepté d'examiner ce travail.

Je n'oublie pas dans mes remerciements Monsieur **ADJABI Mohamed** Chef de Département Electrotechnique ainsi que Pr. **HARKAT M.F** et Dr. **SE. BOUAZZA** sans oublier tout le personnel et collaborateurs des bibliothèques de l'université Badji Mokhtar Annaba pour leur précieuse aide.

Enfin, je ne saurais oublier de trop remercier mes chers parents pour leur soutien le long de ce parcours.

Liste des symboles

x	: Vecteur de données,
N	: Nombre des variables observées,
$X \in \mathcal{R}^{m \times N}$: Matrice de données représentant le fonctionnement normale,
X_j^b	: La j^{ieme} colonne de la matrice X^b ,
M_j	: La moyennede la j^{ieme} colonne,
σ_j^2	: La variance de la j^{ieme} colonne,
X	: La nouvelle matrice des données normalisées,
S	: La matrice de covariance,
l	: Le nombre de composantes principales (PC) retenues (dimension du sous-espace des composantes principales),
$\Lambda = \text{diag}(\lambda_1 \dots \lambda_m)$: La matrice diagonale contient les valeurs propres,
\hat{x}	: Estimation de x par le modèle ACP,
$t \in \mathcal{R}^l$: Le vecteur caractéristique associé à chaque vecteur de données,
t_i	: Sont les composantes principales,
$P \in \mathcal{R}^{m \times l}$: Constituent l'espace de représentation et les $(m - l)$ derniers vecteurs Propres,
P_i	: Les vecteurs propres,
λ_i	: Les valeurs propres,
m	: Le nombre de variables (dimension de l'espace des données mesurées),
k	: Indice de temps,
$\tilde{P} \in \mathcal{R}^{m \times (m-l)}$: Constituent l'espace résiduel avec l est le nombre de composantes principales, (PC) retenue dans le modèle,
$\hat{\lambda}_k$: Le k éme Plus grande valeur propre de $\frac{(n-1)}{n} S$,
l_k	: Le k éme plus grande valeur propre de la matrice de covariance de l'échantillon S ,
D_1 et D_L	: Les détails d'Ondelettes,
y	: La sortie de processus au temps k ,
X_1	: La matrice de sorties de processus retardées,
T^2	: Statistique de Hotteling,

SPE	: Erreur quadratique d'estimation (squared prediction error),
$x^*(k)$: Le vecteur des mesures sans défaut,
$\nabla(k - T_0)$: Une fonction matricielle représentant les profils temporels des défauts,
x^o, Δ et \emptyset	: Représenter le vecteur nominal des mesures, l'erreur de modélisation, et la variation du vecteur mesure due à un défaut, respectivement,
$\alpha_i > 0$: La constante représente les taux d'évolution des défauts inconnus,
$\nabla_i: R \rightarrow R$: Une fonction représentant le profil temporel d'un défaut affectant directement le vecteur x_i ,
e	: Vecteur d'erreurs d'estimation,
δ_α^2	: Le seuil de détectabilité à un niveau de confiance α ,
C_α	: La limite au seuil de confiance $(1 - \alpha)$,
$\chi_{l,\alpha}^2$: Le seuil de détection de T^2 ,
r_i	: ime composante de r ,
r	: Les résidus structurés,
Z_i	: Le vecteur de reconstruction,
$\tilde{\omega}$: Le coefficient corrigé,
$\psi(t)$: La fonction ondelette mère,
$a, b \in R$: Paramètre d'échelle ou dilatation et paramètre de translation,
$\overline{\psi}_a$: L'expression du domaine fréquentiel,
ω_0	: La fréquence centrale de (ω) ,
$\omega_{r(i=1:4)}$: La fréquence angulaire du rotor (rad),
$f_{r(i=1:4)}$: La fréquence de rotation (Hz),
$Z_{(i)(i=1:4)}$: Le nombre de dents,
$f_{en(i)(i=1:4)}$: Les fréquences d'engrènement (Hz),
$T_{en l}$: L'oscillation d'amplitude de couple liée aux fréquences d'engrènements,
J	: Inertie équivalente au niveau du rotor,
p	: Nombre de paires de pôles,
s	: Le glissement du rotor,
ω_s	: La fréquence angulaire fondamentale du stator,
$\emptyset(t)$: Le flux,

Liste des figures

I	Schéma de principe de diagnostic de défauts à base de redondance matérielle (double & triple) et analytique	2
1.1	Analyse en composante principale multi-échelle linéaire	15
1.2	Principe de la modélisation par ACPNL	19
1.3	Orthogonale non linéaire stratégie avec le modèle de Hammerstein	23
2.1	La structure du système FDI	28
2.2	Procédure de détection de défaut par MSE	36
2.3	Procédure de détection par multi-échelle-MSE.....	37
3.1	Distribution Gaussienne. Les zones ombrées centrées aux points -2 et & représentent la probabilité que les distances entre chacun de ces points et tout autre point choisi au hasard parmi les séries chronologiques soient inférieures ou égales à r ,.....	50
4.1	Schémas de système expérimental proposés avec deux types d'accouplement : (a) accouplement flexible (b) accouplement rigide (Photo_dept-électromécanique d'UBMA).....	58
4.2	Diagramme de schéma au dispositif expérimental ($Z_1=26$, $Z_2=73$, $Z_3=18$ et $Z_4=81$) ...	59
4.3	Différent cas d'essai pour le réducteur de vitesse actuelle utilisée dans le test : (1) Cassure locale à l'angle d'un engrenage de dent Z_4 . (2) Piqûres des deux dents de la roue Z_4 . (3) Piqûres des deux dents de la roue Z_2 . (4) Zoom sur les piqûres des deux dents de la roue Z_2	59
4.4	Algorithme de détection des défaillances utilisant l'entropie multi-échelle MSE, statistique multivariée et la décomposition d'Ondelettes	61
4.5-a	Evolutions des différents signaux de courant des phases IA,IB et IC pour le réducteur sans défaillance (état sain) et les défaillances affectant les différents cas (Fig 4.3).....	63
4.5-b	Les signaux de courant ont été enregistrées à partir d'un réducteur de vitesse dans les cinq conditions, y compris : l'état normale, les défaillances d'engrenages (piqûre à dent de roue dentée (Z_2), piqûre à dent de roue dentée (Z_4), piqûres des deux dents des engrenages (Z_2 et Z_4) et la rupture locale à l'angle des dents des engrenages (Z_2 et Z_4).....	63
4.5-c	Evolution des signaux de temps résiduels de la figure 4.5-b	64
4.6	L'évolution de l'analyse en composantes principales du courant de phase IA	64

4.7	Evolution des différents spectres de courant stator pour l'état sain et les défaillances affectant les différents cas (Figure 4.3)	66
4.8	Evolutions des différents spectres des vecteurs Norme de courant statorique pour : (1) l'état sain et (1-5) les défaillances affectant les différents cas (Figure 4.3) (6) la rupture locale sur le coin des dents d'engrenages (Z_2+Z_4) avec raccord flexible et 90 % de la charge nominale	66
4.9	Schéma de référence statorique et rotorique	70
4.10	MSE au cours de 20 échelles du signal de courant de stator correspondant est représenté en figure 4.5-b	73
4.11	Cinq statistique au cours de MSE du signal de courant de phase est représentées sur la figure 4.10	74
4.12	Quatre statistiques au cours de MSE de la phase de signal de courant IA	74
4.13	Quatre statistiques au cours de MSE de la phase de signal de courant IB	74
4.14	Quatre statistiques au cours de MSE de la phase de signal de courant IC	75
4.15	STD au cours de MSE du courant de phase (IA,IB et IC) enregistré à partir d'un réducteur de vitesse dans les cinq conditions	75
4.16	L'exécution des données d'apprentissage par rapport aux données de contrôle	75
4.17	Comparaison des résultats	76
4.18	Evolutions des différentes décompositions en ondelettes pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.12)	77
4.19	Evolutions des différentes décompositions en ondelettes pour les quatre statistiques au cours de MSE du signal de courant de phase IB (illustré par la figure 4.13)	78
4.20	Evolutions des différentes décompositions en ondelettes pour les quatre statistiques au cours de MSE du signal de courant de phase IC (illustré par la figure 4.14)	79
4.21	Evolutions des différents SPE du signal Norme de courant stator pour l'état sain et les différents cas des défaillances (figure 4.3)	81
4.22	Evolutions des différents SPE pour les quatre statistiques au cours de MSE du signal de courant de phase IA pour : (1) l'état sain et (2-5) les défaillances affectant les différents cas (figure 4.3).....	81
4.23	Evolutions des différents SPE approximation A1 pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.20).....	82
4.24	Evolutions des différents T^2 approximation A1 pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.20)	82

4.25	Evolutions des différents T^2 détail30 D1 pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.20).....	83
4.26	CDFs de MCS mesurées de toutes les conditions défectueuses	83
4.27	CDFs de MCS mesurées de toutes les conditions défectueuses en cas des différents études dans le cas d'un couplage rigide et différentes mesures d'a ccouplement flexible	84
4.28	CDFs de MCS mesurées de toutes les conditions défectueuses en cas des différents études dans le cas d'un couplage rigide et différentes mesures d'a ccouplement flexible	84
4.29	Zoom sur CDFs de MCS mesurées de toutes les conditions défectueuses en cas des différents études dans le cas d'un couplage rigide et différentes mesures d'a ccouplement flexible.....	85
4.30	accouplement flexible.....	86
4.31	Les différents variables enregistrés	89
4.32	MSE au cours de 20 échelles du signal de courant de stator correspondant est représenté en figure 4.30.....	90
4.33	Cinq statistiques au cours de MSE du signal de courant de phase est représentées sur la figure 4.31	90
4.34	Mesures et estimations du CO S (HTS)	91
4.35	Mesures et estimations du CO ₂ (106 D).....	91
4.36	Schéma de principe du procédé de synthèse de l'ammoniac	92
4.37	Mesures vapeur / gaz naturel.....	93

Liste des tableaux

2.1	Exemple d'une matrice des signatures théoriques avec quatre résidus	38
2.2	Valeurs de la matrice $M(k)$ en fonction des indicateurs de détection de défauts	40
4.1	Les paramètres électriques de la machine à induction	86
4.2	Matériels de l'accouplement utilisé	86
4.3	Contrôle des paramètres de processus	92

Table des matières

ملخص	i
Abstract	ii
Résumé	iii
Dédicace	iv
Remerciements	v
Liste des symboles	vi
Liste des figures	viii
Liste des tableaux	xi
Table des matières	xii
Introduction Générale	1
Chapitre 1 : Etat de l’art sur les techniques d’analyse en composantes principales	
linéaire et non linéaire (ACP et ACPNL)	7
1.1 Introduction	8
1.2 ACP Linéaire	8
1.3 Principe général de la méthode et identification du modèle ACP	8
1.4 Le choix rationnel et optimale pour déterminer la structure du modèle ACP	10
1.4.1 Pourcentage cumulé de la variance totale (PCV)	11
1.4.2 La théorie de l’information AKAIKE (AIC)	11
1.4.3 Choix de m utilisant des méthodes de validation croisée ou de calcul intensif	12
1.5 Différentes extensions des techniques d’ACP	13
1.5.1 Multi-échelle PCA (MSPCA)	14
1.5.2 ACP dynamique (DACP)	15
1.5.3 Multi-bloc ACP (MBACP)	16
1.6 ACP Non-linéaire (ACPNL)	17

1.6.1	Introduction	17
1.6.2	ACPNL pour la projection et la reconstruction	18
1.6.2.1	Algorithme K-segments	19
1.6.2.2	Réseaux de fonctions à base radiale (RBF)	20
1.6.2.3	Comparaison entre certains réseaux neuronal auto-associé ACPNL	21
1.7	Conclusion	23
Chapitre 2 : Diagnostic, détection & localisation par analyse en composantes principales		
	ACP	24
2.1	Introduction	25
2.2	Détection de défauts	26
2.3	Génération de résidus dans les modèles de redondance	28
2.4	Indices statistiques pour la détection de défauts	29
2.4.1	Limite de contrôle pour la statistique SPE	29
2.4.2	Limite de contrôle pour la statistique T^2	31
2.4.3	Limite de contrôle pour la statistique combinée	32
2.4.4	Limite de contrôle pour la statistique SWE	33
2.5	Méthodes pour la localisation de défauts	34
2.5.1	Localisation par conjointement des méthodes avec l'ACP	34
2.5.1.1	Procédure de détection et localisation par conjointement des méthodes avec l'ACP	35
2.5.1.2	Procédure de surveillance en ligne	37
2.5.2	Méthode d'algorithme d'élimination	37
2.5.3	Méthode de reconstruction des résidus	38
2.5.4	Méthode de reconstruction de variables	39
2.6	Conclusion	41
Chapitre 3 : Filtre basé sur l'analyse d'entropie multi-échelle (MSE) & analyse en Ondelettes		
	Ondelettes	42
3.1	Introduction	43
3.2	Filtre basé sur l'entropie multi-échelle (FME)	44
3.3	SampEn par bloc (BSE)	45
3.4	FME pour gaussien	46
3.5	FME POUR 1/f de bruit	50

3.6 Application de l'analyse en ondelettes au cours de l'analyse MSE	50
3.7 Transformée en ondelettes continue	51
3.8 Ondelettes de Daubechies	51
3.9 La variance et l'entropie d'ondelettes	52
3.10 Théorie des paquets d'ondelettes	53
3.11 Conclusion	54

Chapitre 4 : Développement d'une stratégie de diagnostic & application sur des processus réels 55

Première Partie : Diagnostic des défaillances d'une boîte de vitesses à 3 étages entraînée par une Machine à induction par différentes techniques : l'entropie multi-échelle (MSE), statistique multivariée et les Ondelettes..... 55

4.1 Introduction	56
4.2 Présentation du système expérimental	58
4.3 La méthodologie et les techniques proposées de diagnostic des défaillances	60
4.4 Influence des défaillances dans les différents cas d'études sur MCSA	62
4.4.1 Influence des défaillances sur les grandeurs triphasées.....	62
4.4.2 Influence des défaillances sur l'analyse en composantes principales	64
4.5 Détection des défaillances d'engrenage basée sur l'analyse spectrale	65
4.6 Effet mécanique de la boîte de vitesses dans MCSA	68
4.7 L'équation mathématique du MCSA avec la prise en charge de réducteur « étages	69
4.8 Application de la technique d'entropie multi-échelle MSE au diagnostic	72
4.9 Application de la technique des ondelettes au diagnostic	76
4.10 Détection des défaillances en utilisant des indices de détection	80
4.10.1 Erreur de prédiction au carré SPE	80
4.10.2 Statistique T^2 de Hotelling	80
4.11 Conclusions	85
Annexe	86

Deuxième Partie : Diagnostic de défauts des capteurs des différentes concentrations des gaz présents dans la synthèse de l'ammoniac basée sur l'entropie multi-échelle et statistique multivariées 87

4.13 Introduction	88
4.14 Méthodologie et outils	88
4.15 Conclusion	93
Conclusion et Perspectives.....	94
Références Bibliographiques	96

Introduction générale

La relance de la croissance économique conduit toujours à la création d'innombrables richesses si celle-ci est en constante évolution. Le moindre défaut sur un processus peut engendrer de graves répercussions catastrophiques. C'est pourquoi, le contrôle et la surveillance de la qualité des produits, en temps réel, jouent un rôle essentiel dans n'importe quel processus industriel grâce à l'amélioration de la contrôlabilité de l'ensemble des variables afin d'obtenir un rendement de haute qualité. L'aspect le plus important de la Sécurité de fonctionnement de processus est la détection rapide de toutes défaillances, troubles et/ou d'autres événements spéciaux pouvant survenir en vue de procéder à leur élimination. Cependant, parmi ces variables il y en a certaines qui nécessitent des contrôles réguliers en l'absence de procédé de traitement approprié, d'où des informations spécifiques limitées peuvent être extraites et étudiées minutieusement, avec la prise en compte de la performance et la fiabilité de l'ensemble des moyens de surveillance qui sont liées à la qualité des systèmes de mesures pour s'assurer en continu de la conduite optimale de système de production.

L'idée première, pour s'assurer de la crédibilité d'une mesure consiste à créer une redondance d'informations ; celle-ci peut être obtenue soit par :

1. La redondance matérielle qui est obtenue en multipliant les capteurs qui mesurant une même grandeur. En utilisant, par exemple :
 - a- système duplex, ne permet que la détection d'une panne simple (Fig. I.a).
 - b- système triplex, permet le diagnostic de la panne capteur en utilisant, en cascade, un détecteur et un voteur (Fig. I.b).
 - c- multiplier les chaînes de mesures (Fig. I.c).
2. La redondance analytique qui consiste à utiliser des informations supplémentaires issues de modèles générant des grandeurs homogènes à celle provenant de capteurs. Elle se décompose généralement en deux phases distinctes :
 - a. La génération des résidus caractéristique de la panne avec la prise en compte :
 - Sensibilité maximum aux pannes que l'on cherche à détecter.
 - Sensibilité minimum aux erreurs de modélisation.
 - Bruits de mesure.
 - b. La prise de décision qui a trait à la détection et vraisemblablement à la localisation d'un élément défaillant. Elle met en œuvre des techniques de détection des ruptures et des tests multi-hypothèses.

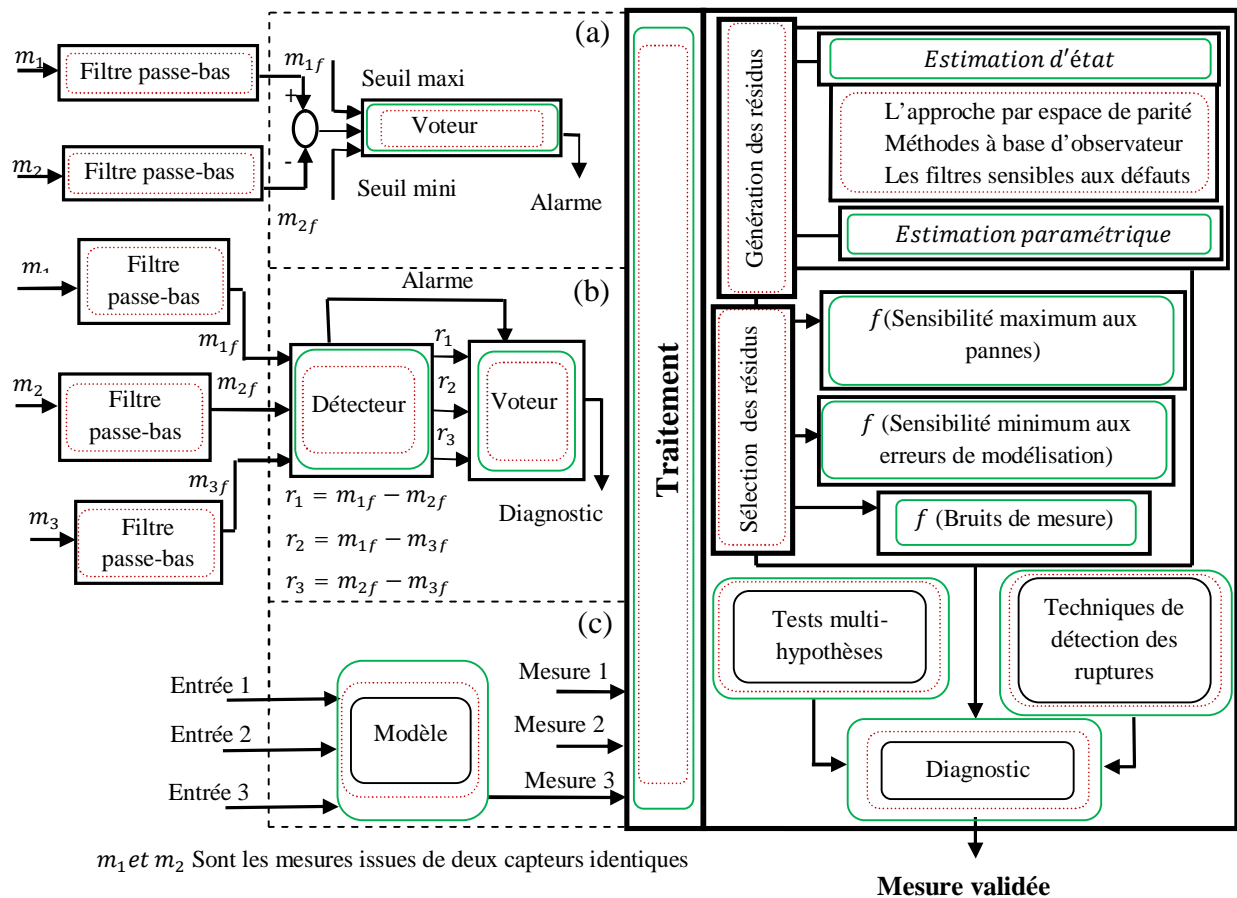
Introduction Générale

L'utilisation des techniques de redondance analytique repose sur la disponibilité d'un modèle de connaissance ou de représentation; elle augmente fortement l'ordre de la redondance et a pour conséquence d'augmenter la fiabilité et la sûreté d'un système de détection, de remplacer un capteur matériel par un capteur mathématique.

La structure générale du système de diagnostic de défaillances à base de redondance matérielle et analytique est représentée sur (Fig.I).

La génération des résidus qui caractérise la défaillance et qui représente les écarts entre le comportement observé du système et le comportement de référence attendu en fonctionnement normal. Les résidus sont obtenus surtout à l'aide des deux approches suivantes :

- Soit par une approche physique qui se base sur l'utilisation d'un modèle de connaissance. Les résidus interprètent le degré d'agrément des lois physiques.
- Soit par une approche mathématique autour d'un formalisme de représentation du type d'état qui conduit au concept d'espace de parité simple et généralisé [1]. Le formalisme d'état est vigoureux et bien adapté à une grande classe de problèmes régis par des équations différentielles.



m_1 et m_2 sont les mesures issues de deux capteurs identiques

Mesure validée

Figure I- Schéma de principe de diagnostic de défauts à base de redondance matérielle (double & triple) et analytique.

Introduction Générale

La redondance analytique ne peut être exploitée que si l'on dispose d'un modèle du système ou du sous-système assemblant les entrées et les sorties mesurées. La technique de redondance analytique permet une exploitation optimale de toutes les informations acquises dans le cadre d'une configuration d'instrumentation donnée. Cela est examiné lorsqu'il s'agit des systèmes de petite dimension. Concernant les systèmes de grande dimension, établir de telles relations mathématiques entre les variables paraissant moins instantanées. Le choix de modèle pour la génération de résidus est despotique et risque que les corrélations entre certaines variables ne soient pas évaluées à cause de la complexité et la grande dimension des processus industriels, il est donc difficile d'établir un modèle mathématique précis dont la qualité est primordiale pour l'obtention d'un système de détection performant. Par conséquent, un outil est nécessaire pour projeter l'espace de processus de grande dimension dans un espace de faible dimension prête à la visualisation directe, et qui peut également identifier les variables clés et les caractéristiques importantes des données. La nécessité d'analyser les données corrélées de processus de grande dimension a conduit au développement de nombreux systèmes de surveillance basés sur l'analyse statistique multivariée. Les méthodes basées sur l'analyse en composantes principales ACP sont plus efficaces pour la détection et localisation de défauts des processus industriels. L'ACP est une technique numérique bien éprouvée dans le domaine du traitement de données pour réduire la dimension d'un ensemble de données dans lequel il existe un grand nombre de variables interdépendantes, tout en conservant autant que possible les variables présentes dans le jeu des données. L'ACP représente un outil de modélisation du comportement de processus plus particulièrement en fonctionnement normal. Ainsi, les défauts sont alors détectés en comparant le comportement observé à celui donné par le modèle ACP.

L'analyse statistique multivariée a reçu une attention considérable et a été largement appliquée dans le domaine de diagnostic des systèmes non linéaires en raison de sa capacité à extraire des informations dans les systèmes multi-variables [2]. Elle est notamment appliquée à des données corrélées qui sont projetées sur des sous-espaces de dimensions réduites dans le but d'extraire toutes les informations appropriées sur le système. En effet, L'ACP linéaire ou non linéaire ACPNL est parfois utilisée comme préalable ou en conjonction avec d'autres techniques des statistiques dans le but d'améliorer et d'assurer un diagnostic robuste de certains types de défauts des processus. Les deux derniers constitueront l'intérêt de nos travaux de recherche menés par la présente thèse. Elle sera appliquée avec des nouvelles approches d'analyse des signatures des défauts basées sur l'application de l'entropie multi-échelle (MSE) et la technique d'adaptation de l'analyse multi-résolution ondelettes (AMRO).

Introduction Générale

L'entropie multi-échelle (MSE) fait référence au calcul des entropies à travers une séquence d'échelles qui prend en considération non seulement la non-linéarité dynamique mais également les effets de l'interaction et de couplage entre les composants du système, offrant ainsi beaucoup plus d'informations sur son fonctionnement. Les ondelettes sont utilisées pour améliorer l'extraction des informations des signaux d'un système non linéaire qui nécessite des choix judicieux pour certains paramètres tels que : la famille d'ondelettes qui a été choisie ayant permis un filtrage optimal du signal traité, ainsi que le nombre de niveau de l'AMRO utilisé a été choisi d'une façon rationnelle et optimale. La stratégie multi-échelle MSE-PCA possède des propriétés intéressantes pour le diagnostic en termes de détection/localisation de défaillance et de robustesse vis-à-vis bruits de mesure.

En effet, l'analyse en composantes principales est une méthode linéaire, alors que dans la pratique la plupart de nombreux procédés ont des comportements non linéaires. Dans ce cas il est difficile d'appliquer seule l'ACP linéaire pour faire la distinction entre le changement de point de fonctionnement et un état de défaillance ce qui présente une grande perte importante de l'information créant une modification de la structure de données.

Plusieurs méthodes d'analyse en composantes principales non linéaire (ACPNL) ont été proposées dans la littérature pour améliorer l'extraction des données lorsque les corrélations non linéaires existent entre les variables. L'approche non linéaire ACP multi-échelles est capable de traiter les signaux avec des extensions non linéaires des stratégies ACP. Lors de l'application de la décomposition en ondelette sur les mesures de processus, les signaux sont projetés sur approximation et de détail. Le coefficient d'approximation est un signal à basse fréquence qui contient les caractéristiques importantes déterministes sous-jacentes. Les coefficients de détail contiennent des signaux de haute fréquence (caractéristiques stochastiques). Une stratégie multi-échelle ACPNL peut être complémentaire pour la surveillance des processus. Cette dernière fait appel à la transformée en ondelettes, les coefficients d'approximation et les coefficients de détail les plus élevés seront conservés et analysés pour la surveillance des processus avec un niveau de décomposition optimal. Le plus haut niveau (la plus basse fréquence) coefficient de détail est retenu tout simplement de détecter toute déviation localisée pour les données futures. La fonction d'approximation, d'autre part, permet de détecter tout changement significatif dans les caractéristiques des processus ou des conditions d'exploitation. Comme ACP non linéaire est incorporée dans la stratégie de diagnostic visant à améliorer l'extraction des données suivie par l'introduction d'un niveau de décomposition en ondelettes optimale dans un environnement multivariée.

Enfin, un cadre complet pour une stratégie de surveillance du processus est présenté. Des exemples sont donnés pour illustrer les avantages du cadre proposé avant de conclure.

Organisation de la thèse

Après l'introduction générale quatre chapitres constituent ce manuscrit de la façon suivante :

Dans le **premier chapitre**, nous présentons les techniques d'analyse en composantes principales linéaire et non linéaire (ACP et ACPNL). Dans la première partie, nous présenterons le principe général de la méthode et l'identification du modèle ACP; la deuxième étape consiste à déterminer le nombre de composantes principales à retenir par un choix rationnel et optimale dans le but de déterminer la structure du modèle ACP. Des critères de détermination de ce nombre seront ainsi mis en vue. La troisième étape présentera quelques extensions de l'analyse en composantes principales linéaire et non linéaire. Des comparaisons entre certains réseaux neuronal auto-associé ACPNL ont été présentées.

Le deuxième chapitre, présentera les procédures de diagnostic, détection et localisation de défauts par ACP. Dans la première partie, l'ACP est utilisée pour modéliser les relations existantes entre les différentes variables mesurées sur le système; le principe de détection de défauts et la génération de résidus dans les modèles de redondance y sont présentés. La deuxième étape consiste à présenter les indices statistiques pour la détection de défauts avec leurs limites de contrôles. La troisième étape concerne la localisation de défauts avec plusieurs approches en utilisant l'analyse statistique multivariée conjointe des autres méthodes : l'entropie multi-échelle (MSE), l'analyse en ondelettes. L'algorithme de l'entropie multi-échelle (MSE) basé sur l'application de SampEn, pour différentes échelles d'identification, sera présenté avec la procédure de surveillance en ligne.

Le troisième chapitre, présentera le filtre qui se base sur l'analyse d'entropie multi-échelle (FME) & l'analyse en ondelettes. Dans cette partie, nous introduisons l'analyse en ondelettes au cours de MSE. La transformée d'ondelettes extrait les composantes de fréquence inférieure et supérieure du signal original à différentes échelles. Ainsi, nous pouvons examiner la complexité des composantes de fréquence inférieure et supérieure du signal à différentes échelles par la décomposition d'ondelettes aux signaux filtrés obtenus à partir de MSE. Le fait que la décomposition utilise des fonctions bien localisées dans le plan temps-fréquence lui donne beaucoup d'avantages au niveau de la résolution en fréquence de la transformée dépend du facteur de dilatation pour des signaux présentant des variations très rapides, l'analyse en ondelettes est adaptée car l'ondelette va détecter ces variations et analyser celles-ci. Cette particularité rend l'analyse en ondelettes complémentaire à l'analyse de Fourier.

Introduction Générale

Le quatrième chapitre, présente deux applications différentes: la première partie consiste à utiliser de l'entropie multi-échelle & l'analyse en composantes principales et la décomposition en ondelettes pour le diagnostic & la détection de défauts des engrenages par l'analyse de la signature du courant moteur. Les stratégies de la surveillance des réducteurs demeurent une préoccupation particulièrement forte au sein des entreprises aujourd'hui. Les enjeux socio-économiques dépendant de la compétitivité de chacune d'entre elles sont de plus en plus étroitement liés à la qualité de surveillances des réducteurs. Une suite de naissance d'évènements particuliers peut, éventuellement, éclairer d'une défaillance prochaine. Notre étude est d'appréhender cette signature naissante à l'aide d'un diagnostic basé sur les statistiques multivariées.

La deuxième partie sera consacré à la discussion des relations entre les différentes variables des processus de l'usine d'ammoniac par les deux approches de diagnostic : l'entropie multi-échelle et les statistiques multivariées pour surveiller les capteurs des différentes concentrations des gaz présents dans la synthèse de l'ammoniac [3].

Enfin, la conclusion générale récapitule le travail développé, commente les résultats trouvés et indique les perspectives de recherche ouvertes pour cette étude.

1

Etat de l'art sur les techniques d'analyse en composantes principales linéaire et non linéaire (ACP et ACPNL)

Sommaire

1.1	Introduction	07
1.2	ACP Linéaire.....	08
1.3	Principe général de la méthode et identification du modèle ACP.....	08
1.4	Le choix rationnel et optimale pour déterminer la structure du modèle ACP.....	10
1.4.1	Pourcentage cumulé de la variance totale (PCV).....	11
1.4.2	La théorie de l'information AKAIKE (AIC).....	11
1.4.3	Choix de m utilisant des méthodes de validation croisée ou de calcul intensif..	12
1.5	Différentes extensions des techniques d'ACP.....	13
1.5.1	Multi-échelle PCA (MSPCA).....	14
1.5.2	ACP dynamique (DACP).....	15
1.5.3	Multi-bloc ACP (MBACP).....	16
1.6	ACP Non-linéaire (ACPNL).....	17
1.6.1	Introduction	17
1.6.2	ACPNL pour la projection et la reconstruction.....	18
1.6.2.1	Algorithme k-segments.....	19
1.6.2.2	Réseaux de fonctions à base radiale (RBF).....	20
1.6.2.3	Comparaison entre certains réseaux neuronal auto-associé ACPNL.....	21
1.7	Conclusion.....	23

1.1 Introduction

Dans le cadre du diagnostic des défauts, la génération de résidus et la prise de décision se rapportant à la détection et vraisemblablement à la localisation de défaillance, les démarches de la redondance analytique obligent le concepteur du système de surveiller et de sélectionner les résidus satisfaisant le compromis: La sensibilité maximum aux défaillances que l'on cherche à détecter et la sensibilité minimum aux erreurs de modélisation et bruits de mesure.

La maîtrise ou contrôle statistique des procédés CSP constitue en effet la base de contrôle de la performance et le diagnostic des défauts des processus. L'objectif principal de CSP est donc de surveiller l'exécution d'un processus au cours du temps pour vérifier qu'il reste dans un état de contrôle statistique [4]. Et comme une conséquence des interactions simultanées entre les variables qui sont importantes dans les processus complexes ne sont pas considérée, la mise en œuvre des résultats des CSP dans la majorité des variables collectées sur un processus rend l'identification et l'interprétation des dysfonctionnements de processus extrêmement difficile car les techniques utilisées du CSP sont des méthodes uni-variées. Cette étude des interactions simultanées des variables au sujet de l'état du système est précisément le but de l'analyse en composantes principales (ACP) qui est une technique de la statistique multivariée. Celle-ci consiste à transformer des variables corrélées en nouvelles variables décorrélées les unes des autres, tout en conservant au maximum la variance de l'espace originale avec un nombre minimum de dimension [5]. Ces nouvelles variables sont appelées composantes principales qui sont utilisées à des fins d'estimation de la matrice de covariance ou de corrélation des variables, d'analyse et contrôle de l'évolution simultanée de données de régime permanent contenant des relations linéaire entre les variables, de surveillance statistique de processus et diagnostic de fonctionnement de système, à condition que les variables initiales soient redondantes pour découler à la réduction du nombre de variables du processus [6].

1.2 ACP Linéaire

1.3 Principe général de la méthode et identification du modèle ACP

L'analyse en composantes principales (ACP) est utilisée pour réduire les effets du bruit et d'extraire les composantes principales du signal [7]. Soit x un vecteur de données contenant les N variables observées du système est noté $x \in \mathcal{R}^N$. Si l'on suppose qu'il y a m variables observées du système (mesures ou commandes) à l'instant k . Nous pouvons construire une matrice de données $X \in \mathcal{R}^{m \times N}$ dans laquelle chaque ligne représente un échantillon [8] :

$$X = \begin{bmatrix} x_1^T(1) \\ x_2^T(2) \\ \dots \\ x_m^T(N) \end{bmatrix} \quad (1.1)$$

La moyenne et la covariance des variables sont calculées à partir de la matrice de données X après centrage et réduction de cette dernière, pour cela on applique à chaque colonne X_j la transformation suivante :

$$X_j = \frac{x_j^b - M_j}{\sigma_j} \quad (1.2)$$

Où x_j^b est la $j^{\text{ième}}$ colonne de la matrice X^b et M_j et σ_j^2 sont respectivement la moyenne et la variance de la $j^{\text{ième}}$ colonne, données par :

$$\begin{cases} M_j = \frac{1}{N} \sum_{k=1}^N x_j(k) \\ \sigma_j = \left(\frac{1}{N} \sum_{k=1}^N (x_j(k) - M_j)^2 \right)^{1/2} \end{cases} \quad (1.3)$$

Le modèle ACP est relativement simple à formuler, pour cela nous avons besoin d'une matrice de données $X^b \in \mathcal{R}^{m \times N}$ où chaque colonne représente une variable à surveiller et chaque ligne représente une observation.

$$X^b = \begin{pmatrix} x_1(1) & x_2(1) & \dots & x_m(1) \\ x_1(2) & x_2(2) & \dots & x_m(2) \\ \vdots & \vdots & \ddots & \vdots \\ x_1(N) & x_2(N) & \dots & x_m(N) \end{pmatrix} \quad (1.4)$$

La nouvelle matrice des données normalisées est notée :

$$X = [X_1 \dots X_m] \quad (1.5)$$

La matrice de corrélation S , à partir de la nouvelle matrice X est donnée par :

$$S \cong \frac{1}{m-1} X^T X \quad (1.6)$$

L'ACP effectue la factorisation de la matrice de covariance pour obtenir les l premiers vecteurs propre $P \in \mathcal{R}^{m \times l}$ qui constituent l'espace de représentation et les $(m-l)$ derniers vecteurs propres $\tilde{P} \in \mathcal{R}^{m \times (m-l)}$ qui constituent l'espace résiduel avec l est le nombre de composantes principales (PC) retenue dans le modèle.

$$S = \overline{P \Lambda P^T} = [P \quad \tilde{P}] \begin{bmatrix} \Lambda & 0 \\ 0 & \tilde{\Lambda} \end{bmatrix} [P \quad \tilde{P}]^T = P \Lambda P^T + \tilde{P} \tilde{\Lambda} \tilde{P}^T \quad (1.7)$$

La matrice diagonale $\Lambda = \text{diag}(\lambda_1 \dots \lambda_m)$ contient les valeurs propres et la matrice diagonale $\tilde{\Lambda}$ contient les valeurs propres sous espaces résiduelles où les termes diagonaux sont donnés dans l'ordre décroissant.

$$x = \hat{x} + \tilde{x} \quad (1.8)$$

Le vecteur caractéristique $t \in \mathcal{R}^l$ est associé à chaque vecteur de données dont il optimise la représentation au sens de la minimisation de l'erreur d'estimation de x ou la minimisation de la variance de t . Les vecteur t et x sont liés par une transformation linéaire suivante :

$$t = P^T x \in \mathcal{R}^l \quad (1.9)$$

Avec $t = [t_1 t_2 \dots t_m]$, où les t_i sont les composantes principales.

et $P = [P_1 P_2 \dots P_m]$, où les vecteurs orthogonaux P_i sont les vecteurs propres correspondant aux valeurs propres λ_i de la décomposition en valeurs et vecteurs propres de la matrice de covariance S . Cette dernière peut se mettre sous la forme suivante :

$$S = \sum_{i=1}^m \lambda_i P_i P_i^T \quad (1.10)$$

S'il existe q relations linéaires entre les colonnes de X , on aura q valeurs propres nulles et la matrice X représentée par les $(m - q) = l$ composantes principales, il est donc obligatoire de déterminer le nombre de composantes à retenir l .

Avec:

$$\hat{x} = PP^T x = Pt \quad (1.11)$$

$$\tilde{x} = \tilde{P}\tilde{P}^T x = \tilde{C}x \quad (1.12)$$

$$\hat{C}_l = \hat{P}_l \hat{P}_l^T \quad (1.13)$$

$$\tilde{C}_{m-l} = I_m - \hat{C}_l \quad (1.14)$$

L'équation (1.13) et (1.14) constituent le modèle ACP. Les ($\hat{x} = x\hat{C}$ et $x\tilde{C}_{m-l} = E$) représentent les variations modélisées et les variations non modélisées de x à partir de l composantes ($l < m$).

1.4 Le choix rationnel et optimale pour déterminer la structure du modèle ACP

Le choix du nombre de PC à retenir c'est la phase la plus importante dans l'identification d'un modèle par ACP. La plupart des approches existantes pour déterminer le nombre de PC utilisent un indice qui diminue de façon monotone. Le nombre de PC est choisi quand il n'y a pas de diminution significative de l'indice après l'ajout d'un PC [9]. Dans le cadre de l'application de l'ACP au diagnostic, le nombre de PC a un impact significatif sur chaque étape de l'algorithme qui peut être implémenté de manière répétitive pour identifier de multiples défauts qui ne se produisent pas simultanément. Il est inhabituel d'avoir plus d'un défaut simultanément. Ce fait permet de distinguer entre la défaillance d'un élément et une condition de fonctionnement anormale où un groupe de variables s'écarte de la corrélation normale établie par le modèle de la composante principale [10]. La fiabilité de l'algorithme de diagnostic par ACP, dépend de la détermination de la structure du modèle. La tactique utilisée

était de ne pas prendre un nombre suffisamment grand de PC pour ne pas risquer d'avoir des PC retenues qui sont porteuses de bruit blanc, d'un autre côté il ne fallait pas le prendre si peu de PC pour ne pas risquer de perdre les informations utiles dans les données de départ. Pour faire un compromis entre ces deux exigences, un choix rationnel et optimal à la fois s'avère nécessaire.

Récemment A. Benaïcha et al [11] ont proposé une technique basée Sur le principe de la reconstruction des variables, pour la détermination du modèle PCA optimisant la détection et l'isolement des défaillances simples et multiples sur des variables redondantes ou non redondantes.

1.4.1 Pourcentage cumulé de la variance totale (PCV)

Pour sélectionner un pourcentage cumulé de variation totale que l'on souhaite que les PC sélectionnés contribuent, disons 80% ou 90%. Le nombre requis de PC est alors la plus petite valeur de m pour laquelle ce pourcentage choisi est dépassé. Les composantes principales sont successivement choisies pour avoir la plus grande variance possible, et la variance du j ème PC est l_k . C'est-à-dire la somme des variances des PC est égale à la somme des variances des éléments de x . La définition évidente du pourcentage de variation relevé par les premiers m de PC est donnée par [12] :

$$PCV(l_k) = 100 \left(\frac{\sum_{j=1}^{l_k} \lambda_j}{\sum_{j=1}^m \lambda_j} \right) \% \quad (1.15)$$

L'efficacité de fournir le nombre optimal des PCs dépend du rapport signal sur le bruit puisque la variance du bruit est inconnue.

1.4.2 La théorie de l'information AKAIKE (AIC)

La série observée x_i est la somme du signal s_i et du bruit blanc additif n_i . La sortie filtrée \hat{s}_i est donnée par [13-15] :

$$\hat{s}_i = \sum_{j=-m}^l B_j x_{i+j} \quad (i = 1, 2, \dots, N) \quad (1.16)$$

Où B_j est déterminé à partir de l'échantillon x_i ($i = 1, 2, \dots, N$). Le problème est de savoir comment définir l et m de sorte que l'erreur de lissage moyenne sur les N échantillons soit minimisée.

$$E\left[\left(\frac{1}{N}\right) \sum_{i=1}^N (s_i - \hat{s}_i)^2\right] \quad (1.17)$$

Dans le cas de l'identification statistique, il est généralement donné plusieurs familles $f(x, \theta)$, avec différentes formes de $f(x|\theta)$, mais avec des restrictions différentes sur le vecteur de paramètre θ et il est nécessaire de décider du meilleur choix de $f(x|\theta)$.

$$AIC(\hat{\theta}) = (-2) \log(\text{maximum de vraisemblance}) + 2k \quad (1.18)$$

k est le nombre de paramètres ajustés indépendamment pour obtenir $\hat{\theta}$.

Une procédure naturelle pour l'ajustement d'un modèle de processus gaussien stationnaire à moyenne nulle à la séquence des observations x_1, x_2, \dots, x_N est de définir un modèle Gaussien stationnaire primitif avec les matrices de covariance $R(l)$, qui sont définies par:

$$R(l) = \begin{cases} \left(\frac{1}{N}\right) \sum_{n=1}^{N-1} x_n + l x_n' & l = 0, 1, 2, \dots, N-1 \\ =0, & l = N, N-1, \dots \end{cases} \quad (1.19)$$

$$AIC(l) = (-2) \log f(x|\hat{\theta}) + 2G(\hat{\theta})$$

$$f(x|\hat{\theta}) = N \sum_{i=l+1}^m \lambda_i - N(m-l) \log\left(\frac{1}{m-l} \sum_{i=l+1}^m \lambda_i\right) \quad (1.20)$$

$$G(\hat{\theta}) = l(2m-l) \quad (1.21)$$

Le critère AIC se base uniquement sur les valeurs propres de la matrice de covariance des données.

1.4.3 Choix de m utilisant des méthodes de validation croisée ou de calcul intensif

L'idée générale de la validation croisée est articulée principalement sur la prédiction à travers un modèle ACP d'une mesure x_i de la matrice de données X .

Une grande quantité de recherche a été faite sur les règles pour choisir m depuis Wold (1978) Jusqu'à Besse et Falguerolles (1993), Notent qu'ils reflètent la caractéristique importante de la stabilité des sous-espaces retenus. Ferré (1990) [13] montre qu'une bonne estimation de f_q :

$$\hat{f}_q = \sum_{k=q+1}^p \hat{\lambda}_k + \sigma^2 [2q(n+q-p) - np + 2(p-q) + 4 \sum_{l=1}^q \sum_{k=q+1}^p \frac{\hat{\lambda}_l}{(\hat{\lambda}_l - \hat{\lambda}_k)}] \quad (1.22)$$

Où $\hat{\lambda}_k$ est le k éme Plus grande valeur propre de $\frac{(n-1)}{n} S$

$$\hat{\lambda}_k = \frac{(n-1)}{n} l_k \quad (1.23)$$

Où l_k est le k ème La plus grande valeur propre de la matrice de covariance de l'échantillon S .

Pour le choix de m , Wold (1978) et Eastment et Krzanowski (1982) Chacun utilise une fonction différente de $PRESS(m)$ comme critère pour choisir m , Décider d'inclure ou non m des PC.

Le critère de la validation croisée représente une minimisation de la somme des carrés des erreurs de prédiction. Il est donné par :

$$PRESS(l) = 1/Nm \sum_{k=1}^N \sum_{i=1}^m (\hat{x}_i^{(l)}(k) - x_i(k))^2 \quad (1.24)$$

Avec N étant la taille du jeu de validation.

Besse (1992) Montre que des paires de vecteurs propres consécutifs sont instables si leurs valeurs propres correspondantes sont de taille similaire.

1.5 Différentes extensions des techniques d'ACP

Différentes extensions de la méthode ACP ont été proposées pour améliorer sa capacité de surveillance. Dans [16] La méthode ACP et PLS est étendue aux situations où les processus peuvent naturellement être bloqués en sous-sections et dans [17] une nouvelle approche effectue une décomposition orthogonale sur l'espace variable de régression pour éliminer les variations inutiles pour la prédiction de sortie. La méthode multi-bloc ACP (MBACP) est utile pour le suivi de processus complexes et permet d'identifier et d'isoler rapidement la section de la plante où l'anomalie s'est produite [18]. L'analyse pondérale exponentielle des composantes principales (EWM-ACP) est aussi une autre extension utile Il fournit des fenêtres multivariées sur un processus dynamique, où les caractéristiques dominantes de l'évolution du processus sont affichées comme des scores plus une mesure de la distance où les données du processus sont à partir du modèle [19]. Une autre extension utile est la méthode ACP dynamique (DACP) proposée dans [20], où des mesures décalées ont été utilisées pour tenir compte de la dynamique des processus. Multi -échelle ACP (MSACP), qui a été proposé dans [21], combine l'analyse d'Ondelettes et la méthode ACP. MSACP extrait simultanément la corrélation croisée entre les capteurs (méthode ACP) et l'autocorrélation à l'intérieur d'un capteur (par analyse d'Ondelettes) [22].

1.5.1 Multi-échelle PCA (MSPCA)

Lors de l'utilisation de la ACP, la corrélation entre les capteurs est utilisée pour transformer l'espace multivarié en un sous-espace qui préserve la variance maximale de la corrélation à l'intérieur du capteur le long du temps. Les Ondelettes, d'autre part, capturent la corrélation à l'intérieur d'un capteur tandis que la ACP est corrélée à travers les capteurs. Ainsi, les ondelettes et l'analyse ACP des données multivariées représentent deux extrêmes, l'un utilisant uniquement les tendances du signal et l'autre utilisant uniquement la corrélation [22].

L'idée d'utiliser conjointement l'ACP et les Ondelettes a été proposée par Wickerhauser (1994) qui a proposé une approximation de l'ACP en utilisant l'algorithme de meilleure base conjointe sur la décomposition par paquets d'ondelettes des données multivariées. Coifman et Saito (1996) ont proposé une approche ACP locale en appuyant sur la transformation cosinus locale sur les données et en sélectionnant les bases qui captent la variance maximale. Au lieu d'appliquer l'ACP sur les données du domaine temporel, Kosanovich et Piovoso (1997) ont appliqué l'ACP sur les coefficients d'ondelettes pour la surveillance des processus. Bakshi (1998) a développé une formulation MSPCA et a démontré son efficacité pour le suivi des processus multivariés [23].

Pour la formulation MSACP, considérer des données $n \times m$ d'une matrice X ayant m variables et N échantillons. Chacune des m colonnes est d'abord décomposée individuellement en appliquant une transformée en Ondelettes discrètes (DWT).

On peut noter que la même transformée en ondelettes avec le même niveau de décomposition, L , est appliquée à chacune des m variables. Les approximations d'Ondelettes A_L de chacune des m décompositions sont collectées dans une matrice de taille $m \times N/2^L$ (comme le montre la matrice de ligne continue A_L de la figure 1.1).

De manière similaire, les détails d'Ondelettes (D_1 à D_L forment chacun des niveaux L) de chacune des m décompositions sont collectées en L matrices correspondantes (comme le montrent les matrices de pointillés D_L et D_1 de la figure 2) avec une matrice de taille variant $/2^i$ ($i = 1, 2, \dots, L$). Ainsi un total de $L + 1$ matrices est formé, chacune étant représentée à une échelle différente, et les tendances capturées dans les capteurs à l'échelle correspondante.

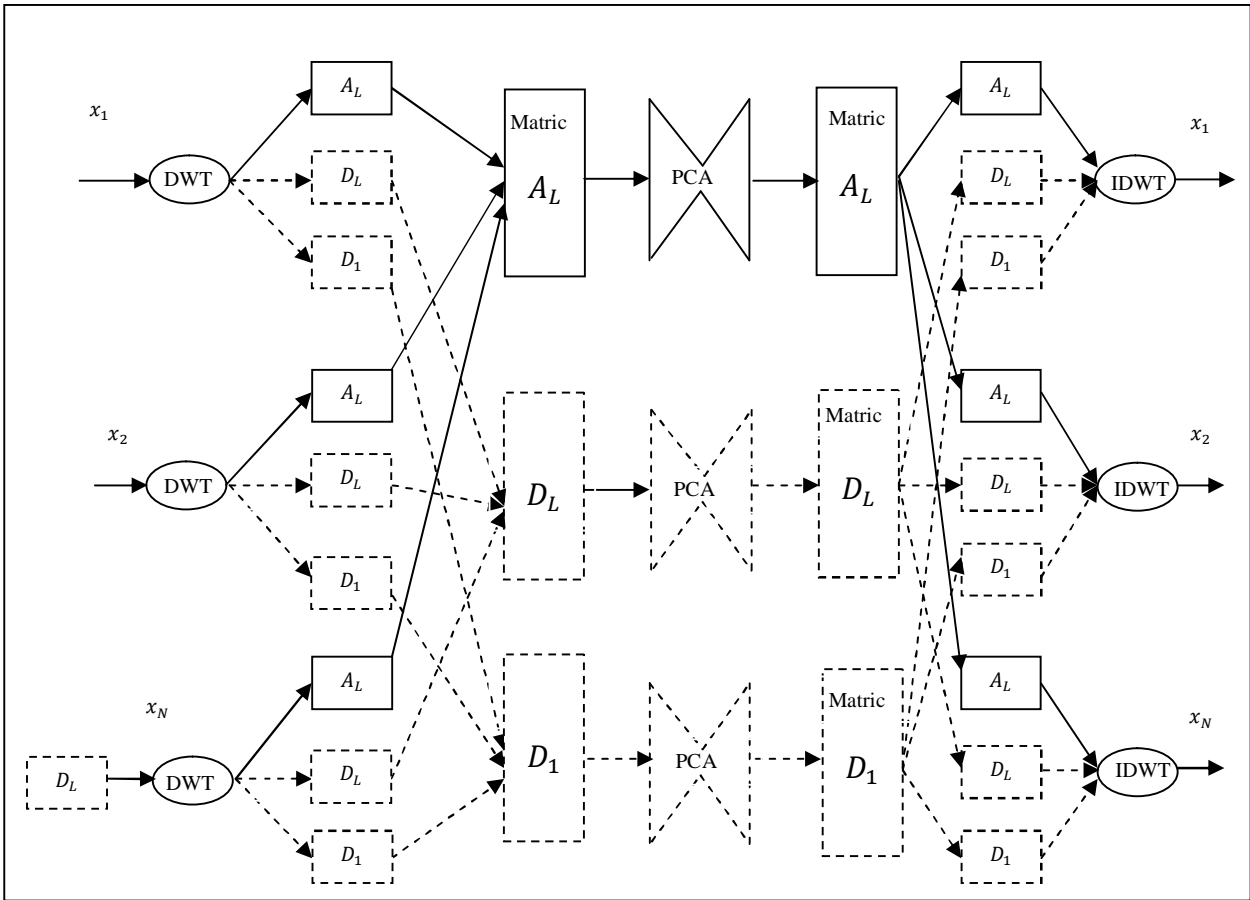


Figure 1.I- Analyse en composante principale multi-échelle linéaire.

1.5.2 ACP dynamique (DACP)

L'application de l'analyse de la matrice de données par l'ACP, qui est basée sur des échantillons provenant d'un processus stationnaire est différente par rapport à un processus dynamique, des procédures spéciales sont nécessaires. Considérons un modèle de processus variable linéaire, invariant dans le temps, discret, à entrée unique, auto-récursif:

$$y(k) = a_1 y(k-1) + \dots + a_n y(k-n) + b_1 u(k-1) + b_m u(k-m) \quad (1.25)$$

La sortie de processus y au temps k est linéairement liée aux n sorties passées et aux m entrées passées u .

$$X_1 = \begin{bmatrix} y(k) & y(k-1) & \dots & y(k-n) & u(k-1) & \dots & u(k-m) \\ y(k+1) & y(k) & \dots & y(k-n+1) & u(k) & \dots & u(k-m+1) \\ y(k+2) & y(k+1) & \dots & y(k-n+2) & u(k+1) & \dots & u(k-m+2) \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ y(k+p) & y(k+p-1) & \dots & y(k+p-n) & u(k+p-1) & \dots & u(k+p-m) \end{bmatrix} \quad (1.26)$$

Où X_1 Une matrice de sorties de processus retardées et d'entrées composées de $y(k)$ à $y(k - n)$ avec les dernières m valeurs des entrées de processus.

$$X_2 = \begin{bmatrix} y(k) & y(k-1) & \dots & y(k-n) \\ y(k+n+1) & y(k+n) & \dots & y(k+1) \\ \vdots & \vdots & \vdots & \vdots \\ y(k+p(n+1)) & y(k+p(n+1)-1) & \dots & y(k+p(n+1)-n) \end{bmatrix} \quad (1.27)$$

La matrice X_2 sous forme d'une fenêtre mobile de largeur constante qui ne contenait pas de lignes qui se chevauchent [24].

Où $n + 1$ est la largeur de la fenêtre mobile, et $p + 1$ est le nombre de fenêtres utilisées dans la matrice.

1.5.3 Multi-bloc ACP (MBACP)

L'analyse (MBACP) divise le processus à grande échelle en plusieurs blocs afin d'améliorer la capacité du modèle à diagnostiquer. Selon Westerhuis JA et al [25] les scores dans la MBACP peuvent être calculés directement à partir de la ACP régulière. S. Qin, S. Valle et al. [26] ont également proposé le concept de contribution de bloc pour but de simplifier le diagnostic de défauts [27] et ont approuvé que les charges peuvent également être calculées à partir de l'algorithme ACP régulier.

Les procédures de base pour le diagnostic et la détection des défauts réalisés par la MBACP avec la contribution du bloc. Pour analyser les variables dans le vecteur de données, les charges et la matrice de corrélation sont comme suit:

$$X = \begin{bmatrix} X_1 \\ \vdots \\ X_b \\ \vdots \\ X_B \end{bmatrix} \quad \tilde{X} = \begin{bmatrix} \tilde{X}_1 \\ \vdots \\ \tilde{X}_b \\ \vdots \\ \tilde{X}_B \end{bmatrix} \quad P = \begin{bmatrix} P_1 \\ \vdots \\ P_b \\ \vdots \\ P_B \end{bmatrix} \quad \tilde{P} = \begin{bmatrix} \tilde{P}_1 \\ \vdots \\ \tilde{P}_b \\ \vdots \\ \tilde{P}_B \end{bmatrix} \quad (1.28)$$

$$R = \begin{bmatrix} R_1 & & & & \\ & & & & \\ & & R_b & & \\ \vdots & & \vdots & & \vdots \\ & & & & R_B \end{bmatrix} \quad (1.29)$$

Les m variables dans le vecteur de données sont séparées en blocs B , chacun représentant un sous-ensemble de toutes les variables disponibles. La matrice de chargement originale est

analysée en un ensemble de charges de blocs. La mise en œuvre de la matrice de corrélation est nécessaire pour déterminer les limites de contrôle. m_b Les variables données dans le bloc b , les paramètres sont créés qui prennent les dimensions suivantes: $X_b \in R^{m_b \times 1}$, $\tilde{X}_b \in R^{m_b \times 1}$, $P_b \in R^{m_b \times l}$, $\tilde{P}_b \in R^{m_b \times (m-l)}$, $R_b \in R^{m_b \times m_l}$. Cette représentation des blocs permet de regrouper les variables adjacentes. L'algorithme MBACP basé sur les étapes suivantes.

- 1 Collecter les données du processus dans des conditions normales.
- 2 Prétraiter et construire le modèle ACP régulier de toutes les variables.
- 3 Bloquer les scores et les chargements acquis par la procédure 1 en fonction de la connaissance du processus.
- 4 Calculer la limite de confiance du bloc SPE.
- 5 Recueillir un nouvel échantillon.
- 6 Surveiller le processus en utilisant le SPE dans la procédure 1.
- 7 Faire un test si un défaut est détecté si SPE est hors limite en continu.
- 8 Une fois qu'un défaut a été détecté, calculer le bloc SPE.
- 9 Le bloc dont la SPE est hors de limite peut être considéré comme la source de la faute ou principalement affecté par le défaut.
- 10 Tracez la contribution variable de ce bloc et localisez la cause racine du défaut avec la connaissance du processus.

1.6 ACP Non-linéaire (ACPNL)

1.6.1 Introduction

L'analyse en composantes principales (ACP) est l'une des méthodes les plus utilisées, car il s'agit d'une méthode simple et non paramétrique pour extraire des informations pertinentes de grandes dimensions. Des méthodes de processus confondues utilisées systématiquement dans le diagnostic de défauts. Cependant, l'ACP est une méthode de projection linéaire qui ne permet pas de décrire efficacement les caractéristiques non linéaires existant dans les processus industriels les plus complexes. Pour faire face à ce problème, des versions étendues de l'ACP adaptées à la manipulation de systèmes non linéaires ont été développées. Tan et Mavrovouniotis (1995) [28] ont décrit une méthodologie alternative non linéaire basée sur la notion de réseau neuronal d'entrée-formation (IT-net). Dunia et Qin (1998, 2000) [29] [30] ont analysé systématiquement les méthodes ACP utilisées dans le diagnostic de défaillances. ACP ou analyse de corrélation pour estimer le nombre de paramètres qui sont plus grands que la taille de l'échantillon. En ce sens, cet argument peut être aussi efficace lorsqu'il est appliqué à des études impliquant des modèles basés sur les réseaux neuronaux (NN). Kramer [31] a

développé une méthode ACPNL basée sur des réseaux neuronaux auto-associatifs. Dong et McAvoy [32] ont présenté une méthode ACP non linéaire basée sur les courbes principales et les réseaux neuronaux. Mavrovouniotis (1995) a montré qu'un réseau IT avec une seule entrée est équivalent à l'approche de la courbe principale de Hastie et Stuetzle (1989) [33]. Webb [34] a proposé une approche pour ACP en usage de deux réseaux de fonctions de bases radiales (RBF) à trois couches en cascade.

Plusieurs méthodes ACPNL ont été proposées dans la littérature pour améliorer l'extraction des données lorsque les corrélations non linéaires entre les variables existent [35] [36]. Certaines combinaisons ACP non linéaires et Ondelettes ont été rapportées [37]. L'objectif de l'ACPNL est d'enlever les relations linéaires et non linéaires entre les différentes variables d'un processus. L'ACPNL a le même principe que l'ACP sauf qu'elle représente les données avec une courbe lisse qui minimise les déviations orthogonales entre les points de données et leurs projections sur cette courbe et qui est déterminée par les relations non linéaires de toutes les modèle ACPNL existant.

1.6.2 ACPNL pour la projection et la reconstruction

La NLPCA permet la projection et la reconstruction d'être une fonction non linéaire arbitraire. La projection non linéaire se présente sous la forme [38]:

$$y_i(t) = G_i(y_x(t)), \quad i = 1, 2, \dots, n. \quad (1.30)$$

Où $y_x(t) = [y(x_1 + t), \dots, y(x_N + t)]^T \in R^N$ et n est la dimension réduite dans le domaine temporel $n < N$. La forme vectorielle est donnée par :

$$y(t) = G(y_x(t)) \quad (1.31)$$

Où $y(t) = [y_1(t), \dots, y_n(t)]^T \in R^n$ et $G(.) = [G_1(.), \dots, G_n(.)]^T: R^N \rightarrow R^n$ et $G(.) : R^N \rightarrow R$ est appelé le i ième axe principal spatial non linéaire. La reconstruction est complétée par une seconde fonction non linéaire $H(.) : R^{n+1} \rightarrow R$ comme suit :

$$y_n(x, t) = H(x, y(t)) \quad (1.32)$$

L'erreur de reconstruction est donné par $e(x, t) = y(x, t) - y_n(x, t)$. Avec les fonctions G et H qui sont sélectionnées pour minimiser la fonction objective suivante :

$$\min_{G,H} < \|e(x, t)\|^2 \quad (1.33)$$

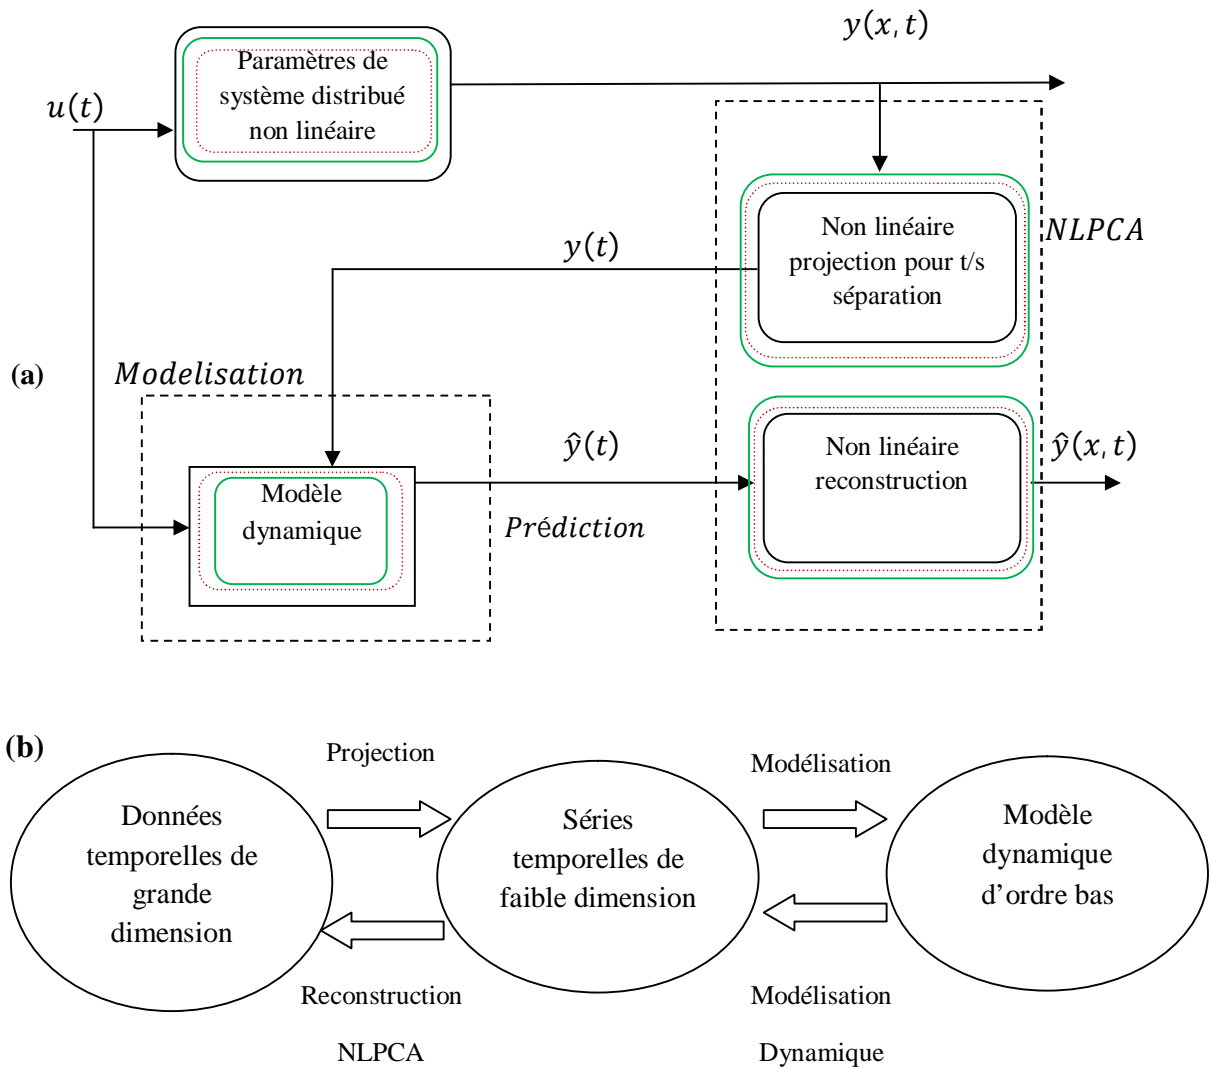


Figure 1.2- Principe de la modélisation par ACPNL.

La figure 1.2 (b) indique l'approche de réduction de dimension non linéaire qui comporte deux fonctions :

- projection non linéaire pour la séparation temps / espace.
- reconstruction d'espace temporel non linéaire.

La figure 1.2 (a) consiste à apprendre la projection non linéaire et la reconstruction à l'aide de la méthode ACPNL et avec la modélisation dynamique de système.

Nous allons présenter dans la suite les différentes approches pour l'extraction des ACPNL.

1.6.2.1 Algorithme k-segments

Verbeek [39] propose une méthode incrémentale pour trouver les courbes principales. Des segments de ligne sont montés et connectés pour former des lignes polygonales (PL). Verbeek [39] utilise un paramètre probabiliste pour trouver les courbes principales en maximisant la

log-vraisemblance, si nous supposons que les données sont corrompues par un certain bruit, celles-ci sont modélisées par la forme suivante:

$$p(x) = \int_0^l p(x|t)p(t)dt \quad (1.34)$$

Où $p(x)$ uniforme le long de la courbe et $p(x|t)$ est un Gaussien sphérique situé sur le point t de la courbe, avec une variance constante sur t .

Afin de trouver un PL pour les données nous devons suivre les étapes suivantes:

- Étendre k-moyens à k-lignes.
- De k-lignes à k-segments.
- Segments k incrémentaux.

Le but est de trouver k -lignes s_1, \dots, s_k qui minimisent la distance carrée locale de tous les points à leur ligne la plus proche:

$$\sum_{i=1}^k \sum_{x \in R_i} d(x, s_i)^2 \quad (1.35)$$

Où R_1, \dots, R_k les régions voronoi définissent comme:

$$R_i = \{x \in X_n | i = \arg \min_j d(x, s_j)\} \quad (1.36)$$

Avec $s_i = \{s_i(t) | i \in R\}$, où $s_i(t) = c_i + p_i t$ la distance d'un point x to à une droite s est définie comme suit

$$d(x, s_i) = \inf_{t \in R} \|s_i(t) - x\| \quad (1.37)$$

Pour un ensemble fini donné des points $S_i \subset R^d$ la moyenne que pour un fini donné minimise la distance au carré est donnée par:

$$m = \arg \min_{\mu \in R^d} \sum_{x \in S_i} \|x - \mu\|^2 \quad (1.38)$$

$$\sum_{x \in S_i} \|x - m\|^2 \leq \sum_{x \in S_i} \|x - x_i\|^2 \quad (1.39)$$

La limite inférieure est définie comme suit :

$$\sum_{x \in S_i} d(x, s_i)^2 \leq \sum_{x \in S_i} \|x - m\|^2 \quad (1.40)$$

L'algorithme de Balázs et al [40] a de meilleures performances et un comportement plus robuste lorsque le modèle de génération de données est varié par rapport à l'algorithme de Hastie [41]. Webb [42] a proposé une approche pour ACP basant sur les réseaux de fonctions de bases radiales (RBF). Bharat Bhushan [43] a utilisé une stratégie pour l'extraction de caractéristiques non linéaires basée sur le réseau PL et RBF.

1.6.2.2 Réseaux de fonctions à base radiale (RBF)

Chaque point de référence peut alors être projeté orthogonal sur le segment de droite et que la longueur correspondante le long de la courbe pour chaque point de données représente les

premiers points non linéaires des composantes principales. Si y_1 représente le premier vecteur résultat de la composante principale non linéaire, le vecteur x peut être représenté comme [43]:

$$x = f_1(y_1) + E_1 \quad (1.41)$$

$$E_1 = f_2(y_2) + E_2 \quad (1.42)$$

Où E_1 est le vecteur résiduel. NLACP peuvent être trouvés en projetant les points de données de E_1 sur les segments de droite construits, ces étapes peuvent être répétées pour trouver d NLACP de sorte que toute la variabilité des données soit extraite, en raison du degré élevé de corrélation entre les variables. Si les composantes ($k \ll d$) peuvent expliquer la plupart de la variabilité de données, le vecteur x est représenté par :

$$x \cong F(Y) \quad (1.43)$$

Où $Y = [y_1, y_2, \dots, y_k]$ est la matrice représentant le modèle ACPNL.

La méthode RBF a comme particularité que ces fonctions noyau sont locales est définies par :

$$\varphi(x; c, \sigma) = \exp\left(-\frac{\|x - c\|^2}{2\sigma^2}\right) \quad (1.44)$$

Le RBF multi quadrique prend la forme:

$$\phi^m(x; c^m, \sigma^m) = \sqrt{\sum_{i=1}^d ((x_i - c_i^m)^2 + \sigma^{m^2})} \quad (1.45)$$

où c^m les centres et σ^m les dispersions de ces fonctions. Pour assurer le champ réceptif optimal de chacun des neurones dans la couche cachée, une dispersion de $3\sigma^m/2$ est considérée si :

$w = (w_{i_1}, w_{i_2}, \dots, w_{i_k})$ pour $i = (1, 2, \dots, p)$ pour est la matrice de poids de la couche de sortie, la sortie du réseau est définie comme:

$$z_j = f(c, \sigma, w) = \left[\sum_{i=1}^p w_{ij} \phi^i \right] / \left[\sum_{i=1}^p \phi^i \right] \quad j = (1, 2, \dots, k) \quad (1.46)$$

La fonction objective à minimiser pour la formation du réseau se définit comme suit:

$$\min_{c, \sigma, w} \sum_{s=1}^n \sum_{j=1}^k (z_j - t_j)_s^2 \quad (1.47)$$

Tous les paramètres d'apprentissage liés à la couche cachée du réseau RBF de réduction sont déterminés à l'aide de l'algorithme PL.

1.6.2.3 Comparaison entre certains réseaux neuronal auto-associé ACPNL

Kramer [44] a proposé un modèle ACP non linéaire basé sur le réseau neuronal auto-associatif. ACPNL de Kramer et des méthodes connexes ont été appliquées avec succès à de

nombreux problèmes différents. Par exemple, [45] montre comment la ACPNL de Kramer peut être appliquée aux problèmes de compression d'image. Référence [46] montre comment une autre version de ACPNL peut être utilisée pour un autre problème de compression de données. La référence [47] montre comment une autre version des ACPNL peut être utilisée pour construire des diagrammes de contrôle. La référence [48] montre comment une autre méthode ACPNL peut être utilisée pour estimer le chemin d'une particule dans une accélération de particules. La référence [49] [50] utilise le concept de modèle Hammerstein en incorporant un modèle ACP linéaire dans la stratégie ACPNL pour le contrôle statistique des processus.

La stratégie ACPNL mentionnée précédemment représente l'une des caractéristiques ACP linéaires capables de projeter les données multidimensionnelles à une dimension inférieure. Une autre caractéristique ACP linéaire importante est que les premiers PCs captent toujours la variance la plus élevée des données d'entrée suivie par la seconde et ainsi de suite. Dans ACPNL, les informations de données tendent à être réparties également entre les composantes principales [51].

Afin d'améliorer la propriété d'orthogonalité dans ACPNL, l'algorithme d'apprentissage de Gram-schmidt est appliqué dans ACPNL de telle sorte que le score non linéaire produit soit orthogonal à la fin de la séance d'apprentissage. L'utilisation du processus de Gram-Schmidt permet un concept de contrôle en cascade est exploitée [50].

Naturellement, les réseaux de type ACP non linéaires présentent certains inconvénients par rapport aux réseaux linéaires. L'analyse mathématique des algorithmes d'apprentissage est souvent intrinsèquement difficile, ce qui rend les propriétés des réseaux moins bien comprises [52]. Compte tenu de l'exigence d'orthogonalité et des inconvénients associés aux algorithmes d'apprentissage, une approche alternative utilise le concept de modèle Hammerstein en incorporant un modèle linéaire ACP dans la stratégie ACPNL. Dans la formulation du modèle Hammerstein, les parties non linéaires et linéaires sont séparées en deux blocs, comme le montre la figure 1.3.

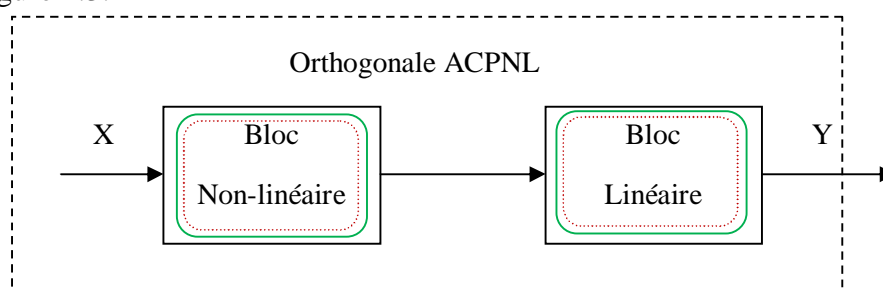


Figure 1.3- Orthogonale non linéaire stratégie avec le modèle de Hammerstein.

1.7 Conclusion

Nous avons présenté le principe des techniques d'analyse en composantes principales linéaire (ACP) et l'analyse en composantes principales non linéaire (ACPNL). Ainsi plusieurs approches utilisées pour la modélisation ACP et ACPNL ont été présentées.

Le but de l'ACP est l'identification des relations linéaires persistantes parmi les différentes variables du système, en utilisant les données d'entrée / sortie du système.

L'identification du modèle ACP consiste donc à estimer les paramètres et la détermination de nombre de composantes principales à retenir. Pour la détermination de ce dernier, plusieurs règles ont été proposées qui privilégient l'approximation de la matrice de données.

Le prochain chapitre est consacré aux méthodes de la détection et localisation par l'ACP, la détection de défauts est réalisée par l'utilisation des indicateurs de détection.

2

Diagnostic, détection & localisation par analyse en composantes principales (ACP)

Sommaire

2.1	Introduction.....	25
2.2	Détection de défauts.....	26
2.3	Génération de résidus dans les modèles de redondance.....	28
2.4	Indices statistiques pour la détection de défauts.....	29
2.4.1	Limite de contrôle pour la statistique SPE	29
2.4.2	Limite de contrôle pour la statistique T^2	31
2.4.3	Limite de contrôle pour la statistique combinée.....	32
2.4.4	Limite de contrôle pour la statistique SWE	33
2.5	Méthodes pour la localisation de défauts.....	34
2.5.1	Localisation par conjointement des méthodes avec l'ACP.....	34
2.5.1.1	Procédure de détection et localisation par conjointement des méthodes avec l'ACP	35
2.5.1.2	Procédure de surveillance en ligne.....	37
2.5.2	Méthode d'algorithme d'élimination.....	37
2.5.3	Méthode de reconstruction des résidus.....	38
2.5.4	Méthode de reconstruction de variables.....	39
2.6	Conclusion.....	41

2.1 Introduction

La procédure de diagnostic à base de modèle essaye de trouver l'adaptation totale des observations traduisant l'état réel du comportement du système. vis-à-vis du modèle représentant le comportement attendu. La comparaison des comportements réels et attendus permet de révéler la présence d'éventuels défaillances voire même de déduire les éléments affectés par une défaillance. Cette procédure peut être décomposée en deux étapes principales désignées sous le nom de:

- Génération des résidus.
- Prise de décision.

L'application des techniques d'analyse en composantes principales (ACP) dans le domaine du diagnostic des systèmes électro-énergétiques a été déjà développée à d'un rythme très rapide [53] [54] [55]. Dans le cadre de la détection de défauts par ACP, plusieurs auteurs utilisent soit:

- La statistique T^2 de Hotelling pour but d'analyse des données représentées dans l'espace principal [56].
- L'erreur quadratique d'estimation *SPE*. (C'est l'indice le plus utilisé dans le cadre de l'ACP) [57].
- Indicateur combiné utilisant l'espace total [58].

Pour la détection de défauts sur les mesures. Un défaut perturbe à la fois les projections des observations dans l'espace principal et dans l'espace résiduel ; donc suivant le modèle utilisé la projection des défauts peut avoir un impact plus important dans les deux espaces [59]. Par conséquent les deux indices de détection jouent des rôles important avec une tactique différente dans la stratégie de diagnostic de défaillance par ACP.

La phase de détection de défauts est liée à la première phase qui concerne la génération de résidus ayant pour but de construire, à partir d'un modèle de bon fonctionnement et des mesures issues des capteurs et des signaux de commande du système, des signaux révélateurs de la présence de défauts, appelés résidus [60]. En fonctionnement normal, un résidu doit être idéalement nul, c'est-à-dire indépendant du point de fonctionnement courant. En pratique, il est différent de zéro car il dépend implicitement des perturbations liées à l'environnement des erreurs de modélisation et des défaillances. La seconde phase d'un module de diagnostic de défauts à base de modèle analytique est appelée de décision et englobe les démarches de détection et de localisation qui concerne l'analyse des comportements pour examiner ceux qui sont anormaux et la détermination précise du comportement incriminé.

Pour la détection des défaillances sur les mesures, l'indice le plus utilisé dans les techniques d'ACP est le *SPE* (Squared prediction error) qui assure la détection de la défaillance dans l'espace résiduel et dépend de toutes les variables à surveiller. La statistique *SPE* est généralement efficace pour détecter les défaillances du processus ou du capteur surtout lorsqu'on l'applique sur des sous-espaces de l'espace résiduel totale et aussi bien sur des indicateurs calculés à partir de signal résiduel [61]. Certains défauts peuvent se produire d'une manière qui n'affecte pas la valeur de *SPE* global surtout lorsqu'on n'utilise l'indice de *SPE* seul. Pour améliorer les capacités de détection par la technique d'ACP, un test basé sur les dernières composantes principales combiné avec des règles de détection a été appliqué pour détecter différents types de défauts [62]. La statistique T^2 de Hotelling mesure les variations des projections des observations dans l'espace principal. Elle est calculée à partir des premières PCs qui ne présentent pas des résidus de plus que les exigences d'emploi de ces dernières. Elles sont peu vérifiées même lorsqu'on les applique sur des indicateurs calculés à partir de signal résiduel. C'est à ce stade que Ye et Qin [63] ont proposé de définir un indice de test global enveloppant tout l'espace de représentation des données. Différentes méthodes de localisation de défauts utilisant l'ACP ont été proposées ces dernières années. Dans le cadre de l'ACP, les deux approches les plus populaires sont basées sur les principes de reconstruction et des contributions aux indices de détection [64].

2.2 Détection de défauts

La détection des défauts permet de déterminer si un défaut s'est produit. Des techniques statistiques multivariées peuvent être utilisées pour détecter les conditions anormales suivantes du capteur:

- Les mesures atteignent des valeurs inhabituelles, souvent causées par une défaillance majeure du capteur.
- Plusieurs capteurs peuvent s'écarter des corrélations normales.
- Le processus surveillé subit des variations transitoires.

Pour la détection des défauts, le modèle ACP du processus est développé. Ce dernier est basé sur les données de processus opérationnelles normales, puis utilisé pour vérifier de nouvelles données de mesure. Les différences entre les nouvelles données de mesure et leurs projections sur le modèle construit des résidus, sont ensuite soumises à une sorte de test statistique pour déterminer s'ils sont significatifs. Habituellement, les indices appelées *SPE*, et la statistique de

Hotelling T^2 sont utilisées pour représenter la variabilité dans le sous-espace résiduel et le sous-espace de la composante principale.

L'existence d'une défaillance dans un système n'est assurée détectable par un indice de détection considéré que sous certaines conditions et ceci grâce aux performances des indicateurs choisis, de l'indice utilisée et notamment de l'amplitude de défaut.

On considère en générale le vecteur des mesures selon la forme suivante:

$$x(k) = x^o(k) + \Delta(x, k) + \nabla(k - T_0)\emptyset(x, k) \quad (2.1)$$

Soit :

$$x^*(k) = x^o(k) + \Delta(x, k) \quad (2.2)$$

$x^*(k)$: est le vecteur des mesures sans défaut, et $\nabla(k - T_0)$ est une fonction matricielle représentant les profils temporels des défauts. Les vecteurs x^o , Δ et \emptyset représentent le vecteur nominal des mesures, l'erreur de modélisation et la variation du vecteur mesure due à un défaut, respectivement.

$$\Delta_i(x, k) \leq \bar{\Delta}_i(x, k) \quad \forall x \in D, \quad \forall k \geq 0 \quad (2.3)$$

D'un point de vue qualitatif, le terme $\nabla(k - T_0)\emptyset(x, k)$ représente l'écart dans la dynamique du vecteur dû à un défaut. La matrice $\nabla(k - T_0)$ caractérise le profil temporel d'un défaut qui se produit à un moment inconnu T_0 et $\emptyset(x, k)$ désigne la fonction de défaut non linéaire.

Le profil de temps de défaut $\nabla(\cdot)$ doit être une matrice diagonale de la forme:

$$\nabla(k - T_0) \cong \text{diag} [\nabla_1(k - T_0), \dots, \nabla_n(k - T_0)] \quad (2.4)$$

Où $\nabla_i: R \rightarrow R$ Est une fonction représentant le profil temporel d'un défaut affectant directement le vecteur x_i .

$$\nabla(k - T_0) \cong \begin{cases} 0 & \text{si } k > T_0 \\ 1 - e^{-\alpha_i(k-T_0)} & \text{si } k \geq T_0 \end{cases} \quad (2.5)$$

Où la constante $\alpha_i > 0$ représente les taux d'évolution des défauts inconnus. Les petites valeurs de α_i caractérisent lentement les défauts de développement, également connus sous le nom de défauts naissants. Pour les grandes valeurs de α_i , $\nabla_i(\cdot)$ s'approche d'une fonction d'étape, qui modèle les défauts abrupts. La projection du vecteur de mesures (2.1) dans l'espace principal est:

$$\hat{t}(k) = \hat{P}^T(k)[x^*(k) + \nabla(k - T_0)\emptyset(x, k)] \quad (2.6)$$

Notons la projection des directions de défauts dans l'espace principal:

$$\hat{\nabla}(k - T_0) = \hat{P}^T(k)\nabla(k - T_0) \quad (2.7)$$

Et la projection de vecteur de mesures sans défaut dans cet espace:

$$\hat{t}^*(k) = \hat{P}^T(k)\hat{x}^*(k) = \hat{P}^T(k)[x^o(k) + \Delta(x, k)] \quad (2.8)$$

On a :

$$\hat{t}(k) = \hat{t}^*(k) + \hat{V}(k - T_0)\phi(x, k) \quad (2.9)$$

De même, la projection du vecteur des mesures (2.1) dans l'espace résiduel donne:

$$\begin{aligned} \tilde{t}(k) &= \tilde{P}^T(k)[x^*(k) + \nabla(k - T_0)\phi(x, k)] \\ &= \tilde{P}^T(k)[x^o(k) + \Delta(x, k) + \nabla(k - T_0)\phi(x, k)] \end{aligned} \quad (2.10)$$

Notons la projection des directions de défauts dans l'espace résiduel :

$$\tilde{V}(k - T_0) = \tilde{P}^T(k)\nabla(k - T_0) \quad (2.11)$$

Et la projection de vecteur de mesure sans défauts dans cet espace:

$$\tilde{t}^*(k) = \tilde{P}^T(k)x^*(k) = \tilde{P}^T(k)\Delta(x, k) \quad (2.12)$$

Notons que la relation:

$$\tilde{P}^T(k)x^o(k) = 0 \quad (2.13)$$

Montre l'existence de $(m - l)$ relations linéaires entre les composantes de $x^o(t)$.

A partir des définitions (2.11) et (2.12), le vecteur des résidus (2.10) s'écrit sous la forme suivante:

$$\tilde{t}(k) = \tilde{t}^*(k) + \tilde{V}(k - T_0)\phi(x, k) \quad (2.14)$$

On peut conclure que la projection des observations dans l'espace résiduel (2.10) est un résidu; elle ne dépend que des défauts $\phi(x, k)$ et des bruits ou erreur de mesure $\Delta(x, k)$ alors que pour la projection des observations dans l'espace principal, il est vrai néanmoins que sur l'influence des données. Un défaut influence les projections des observations dans les deux espaces, toutefois, suivant le type de modèle. La projection de défaut peut avoir une influence considérable dans les deux espaces. Pour détecter des défauts, les deux indices *SPE* et T^2 de Hotelling sont utilisés pour représenter les variations des données dans les deux espaces.

2.3 Génération de résidus dans les modèles de redondance

L'étape de la détection des défauts utilisant le modèle de redondance est passé par la formulation d'un ensemble de résidus qui sont les différences entre les variables mesurées et leurs valeurs attendues à partir du modèle de redondance [65]. Dans la pratique, la présence

de bruit dans le système et de l'inexactitude du modèle sont les raisons pour lesquelles les résidus sont non-zéro. Néanmoins, dans un système sain soumis au bruit, les résidus devraient avoir une distribution de probabilité normale avec une valeur attendue de zéro [66].

Plusieurs méthodes de génération résiduelle sont introduites dans la littérature. La méthode la plus appropriée de la génération résiduelle est l'équation de parité [67]. Les équations de la parité sont une représentation mathématique réarrangée du modèle d'entrée sortie ou d'espace d'état du système qui génère directement un ensemble de résidus des mesures [1].

Deux méthodes majeures d'amélioration des résidus ont été proposées: les résidus structurels et le résidu directionnel [68]. Dans l'approche résiduelle structurelle, les résidus sont conçus de telle sorte qu'un sous-ensemble unique des résidus est orthogonal à un défaut spécifique. Par conséquent, lorsque ce défaut se produit, la valeur attendue de tous les résidus devient non nul sauf ceux correspondant au défaut donné. Dans l'approche directionnelle résiduelle, les résidus sont conçus de telle sorte que chaque défaut fait du vecteur de génération résiduelle attendu un vecteur non nul avec une direction spécifique correspondant à ce défaut. La prochaine étape après la génération résiduelle est le processus de décision [1]. Dans le processus de décision, les résidus sont examinés pour détecter d'abord le défaut, puis pour isoler le défaut dans le système. Un processus de décision peut consister en un simple test de seuil sur les résidus, ou sur la base du calcul des moyennes des résidus, ou il peut être basé sur des méthodes plus avancées de théorie des décisions statistiques [69].




Figure 2.1- La structure du système FDI.

La figure 2.1 montre la structure représentée du système FDI, les sorties des capteurs sont initialement traitées pour améliorer l'effet d'une défaillance. Les mesures traitées sont appelées les résidus et l'effet de défaillance amélioré sur les résidus est appelé signature de la défaillance.

2.4 Indices statistiques pour la détection de défauts

2.4.1 Limite de contrôle pour la statistique *SPE*

La perte d'information induite par la réduction de dimension de la représentation de données est mesurée par la différence e entre ses représentations exactes et celles approchées, et y donnée par:

$$e = x - \hat{x} \quad (2.15)$$

La meilleure modélisation par la technique d'ACP est celle qui présente l'erreur quadratique d'estimation SPE la plus faible:

$$SPE = e^T e \quad (2.16)$$

Le dysfonctionnement d'un processus à l'instant k se traduit par le franchissement de seuil de détection:

$$SPE(t) > \delta_\alpha^2 \quad (2.17)$$

Où δ_α^2 , représente le seuil de détectabilité à un niveau de confiance α , il est obtenu à partir de l'expression suivante [70]:

$$\delta_\alpha^2 = \left[\frac{c_\alpha \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{\frac{1}{h_0}} \quad (2.18)$$

Avec $\theta_i = \sum_{j=l+1}^m \lambda_j^i$ pour $i = 1, 2, 3$ et λ_j est la j éme valeur propre de la matrice S .

$$h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2} \quad (2.19)$$

$$C_\alpha = \frac{\theta_1 \left[\left(\frac{\|e\|^2}{\theta_1} \right)^{h_0} - 1 - \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]}{\sqrt{2\theta_2 h_0^2}} \quad (2.20)$$

C_α est la limite au seuil de confiance $(1 - \alpha)$, ces limites supposent x Suit une distribution normale.

Le seuil de détection δ_α^2 a été quantifié théoriquement par Box [71] avec la comparaison des distributions approximatives et exactes de certaines formes quadratiques. Il a montré que les données suivent une distribution normale sous l'hypothèse :

$$\delta_\alpha^2 = g\chi_{h,\alpha}^2 \quad (2.21)$$

Si un défaut est détectable, son amplitude doit être suffisamment grande pour être suffisamment détectée. Dunia et Qin donnent la condition suffisante de détection de défaut à l'aide de la SPE. Un défaut est garanti pour être détecté par la SPE si :

$$SPE(k) = \|\tilde{t}^*(k) + \tilde{v}(k - T_0)\phi(x, k)\|_2^2 \quad (2.22)$$

Pour que les défauts soient détectables quelles que soient leurs amplitudes, la condition suivante doit être vérifiée [57]:

$$\|\tilde{v}(k - T_0)\|_2 = \sigma_{max}(\tilde{v}(k - T_0)) \neq 0 \quad (2.23)$$

Où $\sigma_{max}(\cdot)$ est la valeur singulière maximale, en appliquant l'inégalité triangulaire à l'équation (2.22), on obtient :

$$\|\tilde{\nabla}(k - T_0)\|_2 \leq \|\tilde{t}(k)\|_2 + \|\tilde{t}^*(k)\|_2 \quad (2.24)$$

Comme $\|\tilde{t}^*(t)\|_2^2$ représente le SPE en fonctionnement normal, alors :

$$\|\tilde{t}^*(k)\|_2 \leq \delta_\alpha \quad (2.25)$$

Et l'équation (2.24) s'écrit sous la forme :

$$\|\tilde{t}^*(k)\|_2 \geq \|\tilde{\nabla}(k - T_0)\|_2 - \delta_\alpha \quad (2.26)$$

En respectant l'inégalité (2.17) et pour garantir que $\|\tilde{t}(t)\|_2 \geq \delta_\alpha$ on obtient alors la condition suivante :

$$\|\tilde{\nabla}(k - T_0)\phi(x, k)\|_2 \geq 2\delta_\alpha \quad (2.27)$$

2.4.2 Limite de contrôle pour la statistique T^2

La mesure qui tient compte de la structure de covariance d'une distribution normale multivariée a été proposée par Hotelling en 1947 et s'appelle Hotelling T^2 [72]. La statistique du T^2 de Hotelling permet de mesurer la variation dans la composante principale à différents échantillons de temps et elle est exprimée comme :

$$\begin{aligned} T^2(k) &= \hat{t}^T(k) \left(\hat{\Lambda} \right)^{-1} \hat{t}(k) = \left\| (\Lambda)^{-\frac{1}{2}} \hat{P}^T \hat{P} \hat{P}^T x(k) \right\|^2 \\ &= \left\| (\Lambda)^{-\frac{1}{2}} \hat{P}^T \left(\hat{P} \hat{P}^T x^*(k) + \hat{P} \hat{P}^T \nabla(k - T_0) \phi(x, k) \right) \right\|^2 \\ &= \left\| \left(\hat{\Lambda} \right)^{-1/2} \hat{t}(k) \right\|_2^2 \end{aligned} \quad (2.28)$$

Où $\hat{\Lambda}$ représente la matrice diagonale contenant les l premières valeurs propres de la matrice de la corrélation S .

Le seuil approprié pour la statistique T^2 pour un seuil de confiance α peut être déterminé par :

$$\chi_{l,\alpha}^2 = \frac{l(N^2-1)}{N(N-l)} F_l(l, N-l) \quad (2.29)$$

Où $F_l(l, N-l)$ est la partie supérieure 100 α % Point critique de la F Distribution avec l et $(N-l)$ degrés de liberté.

La statistique T^2 et avec (2.29) Définit le comportement normal du processus, et un vecteur d'observation à l'extérieur de cette région indique qu'un défaut s'est produit:

$$T^2(k) > \chi_{l,\alpha}^2 \quad (2.30)$$

Où $\chi_{l,\alpha}^2$ est le seuil de détection de T^2 .

Pour que les défauts soient détectables quelles que soient leurs amplitudes, la condition suivante doit être vérifiée

$$\sigma_{\max} \left(\left(\hat{\Lambda} \right)^{-1/2} \tilde{\nabla}(k - T_0) \phi(x, k) \right) \neq 0 \quad (2.31)$$

L'utilisation de la statistique $T^2(k)$ pour but d'assurer la détection de défauts, il faut que l'amplitude $\|\phi(x, k)_{T^2}\|_2$ doive respecter la condition suivante [57] :

$$\|\phi(x, k)_{T^2}\|_2 \geq \frac{2\chi_{l,\alpha}}{\sigma_{\max} \left[\left(\hat{\Lambda} \right)^{-1/2} \tilde{\nabla}(k - T_0) \phi(x, k) \right]} \quad (2.32)$$

Comme les l premières valeurs propres sont différentes de zéro.

$$T^2(k) = \|(\Lambda)^{-1/2} \hat{P}^T(x^*(k) + \nabla(k - T_0)\phi(x, k))\|^2 \geq \|(\Lambda)^{-1/2} \hat{P}^T(\nabla(k - T_0)\phi(x, k))\|^2 - \|(\Lambda)^{-1/2} \hat{P}^T(x^*(k))\|^2 \quad (2.33)$$

Comme $\|(\Lambda)^{-1/2} \hat{P}^T(x^*(k))\|^2$ représente le T^2 en fonctionnement normal et on respectant (2.30) on obtient alors la condition suivante :

$$\left\| \left(\hat{\Lambda} \right)^{-1/2} \hat{P}^T \tilde{\nabla}(k - T_0) \phi(x, k) \right\|_2 \geq 2\chi_{l,\alpha} \quad (2.34)$$

L'utilisation de la statistique T^2 de Hotelling pour but de détection de défauts pour les cas des signaux de très faible amplitude n'est pas adéquate parce que lors des projections des observations dans l'espace principal dues aux défauts peuvent être chevauchées par leurs variations normales.

2.4.3 Limite de contrôle pour la statistique combinée

La statistique combinée utilise en même temps les deux indices SPE et T^2 qui se comportent de manière complémentaire pour obtenir un indice global qui simplifie la tâche de détection de défaut en couvrant tout l'espace de représentation des données [63]. Cette statistique combinée, à pour expression :

$$\varphi = \frac{SPE}{\delta^2} + \frac{T^2}{\tau^2} = x^T \phi x \quad \text{Où} \quad \phi = \frac{\tilde{C}}{\delta^2} + \frac{D}{\tau^2} \quad (2.34)$$

$$\phi = \frac{(I - \tilde{P}\tilde{P}^T)}{\delta^2} + \frac{\hat{P}\Lambda^{-1}\hat{P}^T}{\chi_{\alpha}^2} = \frac{\tilde{P}\tilde{P}^T}{\delta^2} + \frac{\hat{P}\Lambda^{-1}\hat{P}^T}{\chi_{\alpha}^2} \quad (2.35)$$

Notons que \emptyset est une matrice symétrique et définie positive.

Le processus est considéré comme normal si $\varphi \leq \zeta^2$ et la limite de contrôle ζ^2 est :

$$\zeta^2 = g^\varphi x_\alpha^2(h^\varphi) \quad (2.36)$$

$$g^\varphi = \left(\frac{l}{\tau^4} + \frac{\theta_2}{\delta^4} \right) / \left(\frac{l}{\tau^2} + \frac{\theta_1}{\delta^2} \right) = \left(\frac{l\delta^4}{\tau^4} + \theta_2 \right) / \delta^2 \left(\frac{l\delta^2}{\tau^2} + \theta_1 \right) \quad (2.37)$$

$$h^\varphi = \left(\frac{l}{\tau^2} + \frac{\theta_1}{\delta^2} \right)^2 / \left(\frac{l}{\tau^4} + \frac{\theta_2}{\delta^4} \right) = \left(\frac{l\delta^2}{\tau^2} + \theta_1 \right)^2 / \left(\frac{l\delta^4}{\tau^4} + \theta_2 \right) \quad (2.38)$$

Nous mettons $\frac{l\delta^2}{\tau^2} = \beta$ et après avoir obtenu:

$$g^\varphi = \left(\frac{\beta^2}{l} + \theta_2 \right) / \delta^2 (\beta + \theta_1) \quad (2.39)$$

$$h^\varphi = (\beta + \theta_1)^2 / \left(\frac{\beta^2}{l} + \theta_2 \right) \quad (2.40)$$

Avec $(1-\alpha) \times 100\%$ niveau de confiance.

Où g et h désignent respectivement le coefficient et le nombre de degré de liberté.

Après calcul de g^φ et h^φ , le défaut peut être détecté si :

$$\varphi > g^\varphi \chi_\alpha^2(h^\varphi) \quad (2.41)$$

Pour que les défauts soient détectables quelque soient leurs amplitudes, il faut que :

$$\sigma_{max}(\emptyset^{\frac{1}{2}} \nabla(k - T_0) \emptyset(x, k)) \neq 0 \quad (2.42)$$

Pour garantir la détection de défauts en utilisant la statistique combinée, il faut que leurs amplitudes vérifient :

$$\|f_\varphi\|_2 \geq \frac{g^\varphi \chi_\alpha^2(h^\varphi)^{1/2}}{\sigma_{max}(\emptyset^{\frac{1}{2}} \nabla(k - T_0) \emptyset(x, k))} \quad (2.43)$$

2.4.4 Limite de contrôle pour la statistique SWE

La statistique SWE ou de Hawkins peut être définie comme une adaptation de la statistique SPE calculée avec des CPs résiduelles pondérées. Et aussi son expression est comme un ajustement symétrique de la statistique T^2 dans l'espace résiduel [73].

$$SWE(k) = \tilde{t}^T(k) (\tilde{\Lambda})^{-1} \tilde{t}(k) = \left\| (\tilde{\Lambda})^{-\frac{1}{2}} \tilde{t}(k) \right\|^2 \quad (2.44)$$

Où $\tilde{\Lambda}$ représente la matrice diagonale contenant les $m - l$ dernières valeurs propres de la matrice des corrélations S .

Le comportement du processus à la k éme observation est supposé en défaut si :

$$SWE(k) > \chi_{\alpha}^2(h_{SWE,\alpha}) \quad (2.45)$$

Où $\chi_{\alpha}^2(h_{SWE})$ est le seuil de détection de SWE .

La limite de contrôle de l'indice SWE lorsque le nombre d'observation N est faible est approximée par une distribution de Fisher :

$$f^2 = \frac{(m-l)(N^2-1)}{N(N-m+l)} F_{(m-l, N-m+l, \alpha)} \quad (2.46)$$

Pour que les défauts soient détectables quelque soient leurs amplitudes, il faut que :

$$\sigma_{max}((\tilde{\Lambda})^{-\frac{1}{2}} \nabla(k - T_0) \phi(x, k)) \neq 0 \quad (2.47)$$

L'indice SWE n'est déterminé que si les dernières valeurs propres de la matrice $\tilde{\Lambda}$ sont non nulles.

Les mesures étant contaminées par le bruit de mesures, il est peu probable que la matrice $\tilde{\Lambda}$ possède des valeurs propres nulles. Par conséquent, on peut écrire encore :

$$\sigma_{max}(\nabla(k - T_0) \phi(x, k)) \neq 0 \quad (2.48)$$

Pour garantir la détection de défauts en utilisant la statistique SWE , il faut que leurs amplitudes vérifient :

$$\|f_{SWE}\|_2 \geq \frac{g^{\varphi} \chi_{\alpha}^2(h^{\varphi})^{1/2}}{\sigma_{max}((\tilde{\Lambda})^{-\frac{1}{2}} \nabla(k - T_0) \phi(x, k))} \quad (2.49)$$

2.3 Méthodes pour la localisation de défauts

L'étape qui suit la phase de détection de défauts c'est l'étape de localisation ou d'isolation de défauts permettant d'indiquer la ou les variables en cause. Pour ce faire, on construit un ensemble des indicateurs qui résultent à priori de tous les défauts.

Dans le cadre de l'utilisation de l'ACP pour un aspect de diagnostic, le nombre de CPs retenues pour la construction d'un modèle ACP aura nécessairement un impact sur les tâches d'une telle démarche surtout la détection et la localisation de défauts.

2.5.1 Localisation par conjointement des méthodes avec l'ACP

Une nouvelle technique basée sur l'ACP conjointement par l'entropie multi échelle et la décomposition d'ondelettes est présentée pour la détection et l'identification de défauts au cours d'une application de surveillance de processus [61]. L'algorithme de l'entropie multi-échelle (MSE) basé sur l'application de SampEn pour différentes échelles d'identification est présenté [74], qui peut identifier des défaillances dans plusieurs éléments de système.

L'algorithme MSE est sensible aux changements dans les corrélations des systèmes détectés par le contrôle de processus statistique multivarié. L'algorithme MSE est utilisé avec succès pour la détection et localisation de défauts dans le système électro-énergétique. Il est également possible de distinguer les défaillances du processus à l'aide de la décomposition d'ondelettes.

MSE offre une possibilité d'utiliser des indicateurs partiels. Les résidus vont être sensibles aux défaillances associés aux variables qui forment les vecteurs des indicateurs qui sont calculés à partir de MSE. Les défaillances liées aux variables bifurquées n'affecteront pas les résidus correspondants.

La démarche consiste donc à structurer les indices de détections liées après les calculs des indicateurs d'MSE ainsi que les seuils de détection des indices correspondants (figure 2.2).

2.5.1.1 Procédure de détection et localisation par conjointement des méthodes avec l'ACP

La procédure de détection et localisation par conjointement des méthodes avec l'ACP basée sur les étapes suivantes :

1. L'entropie multi-échelle (MSE) algorithme SampEn.
2. Teste multi-échelle.
3. Construire un ensemble de modèles de MSE partielles.
4. Construire des indicateurs partiels. Indi1a, Indi2a, Indi3a, Indi4a.
5. Reconstruction & décomposition optimal d'Ondelettes
6. Déterminer les seuils pour la détection des défauts (seuil δ_i^2 sur l'indice SPE_i).
7. Déterminer les seuils pour la détection des défauts (seuil τ_j^2 sur l'indice T_j^2).

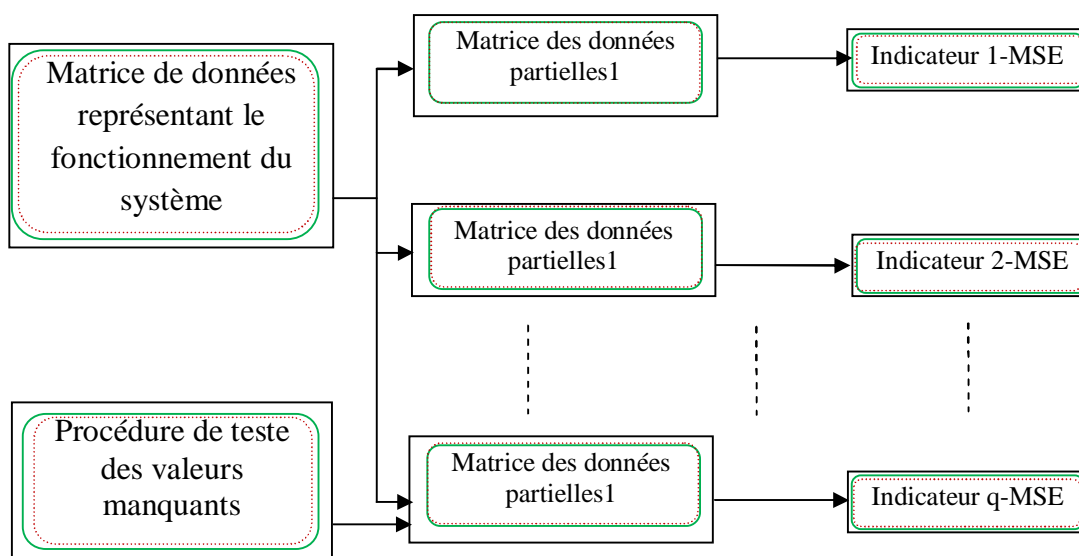


Figure 2.2- Procédure de détection de défaut par MSE.

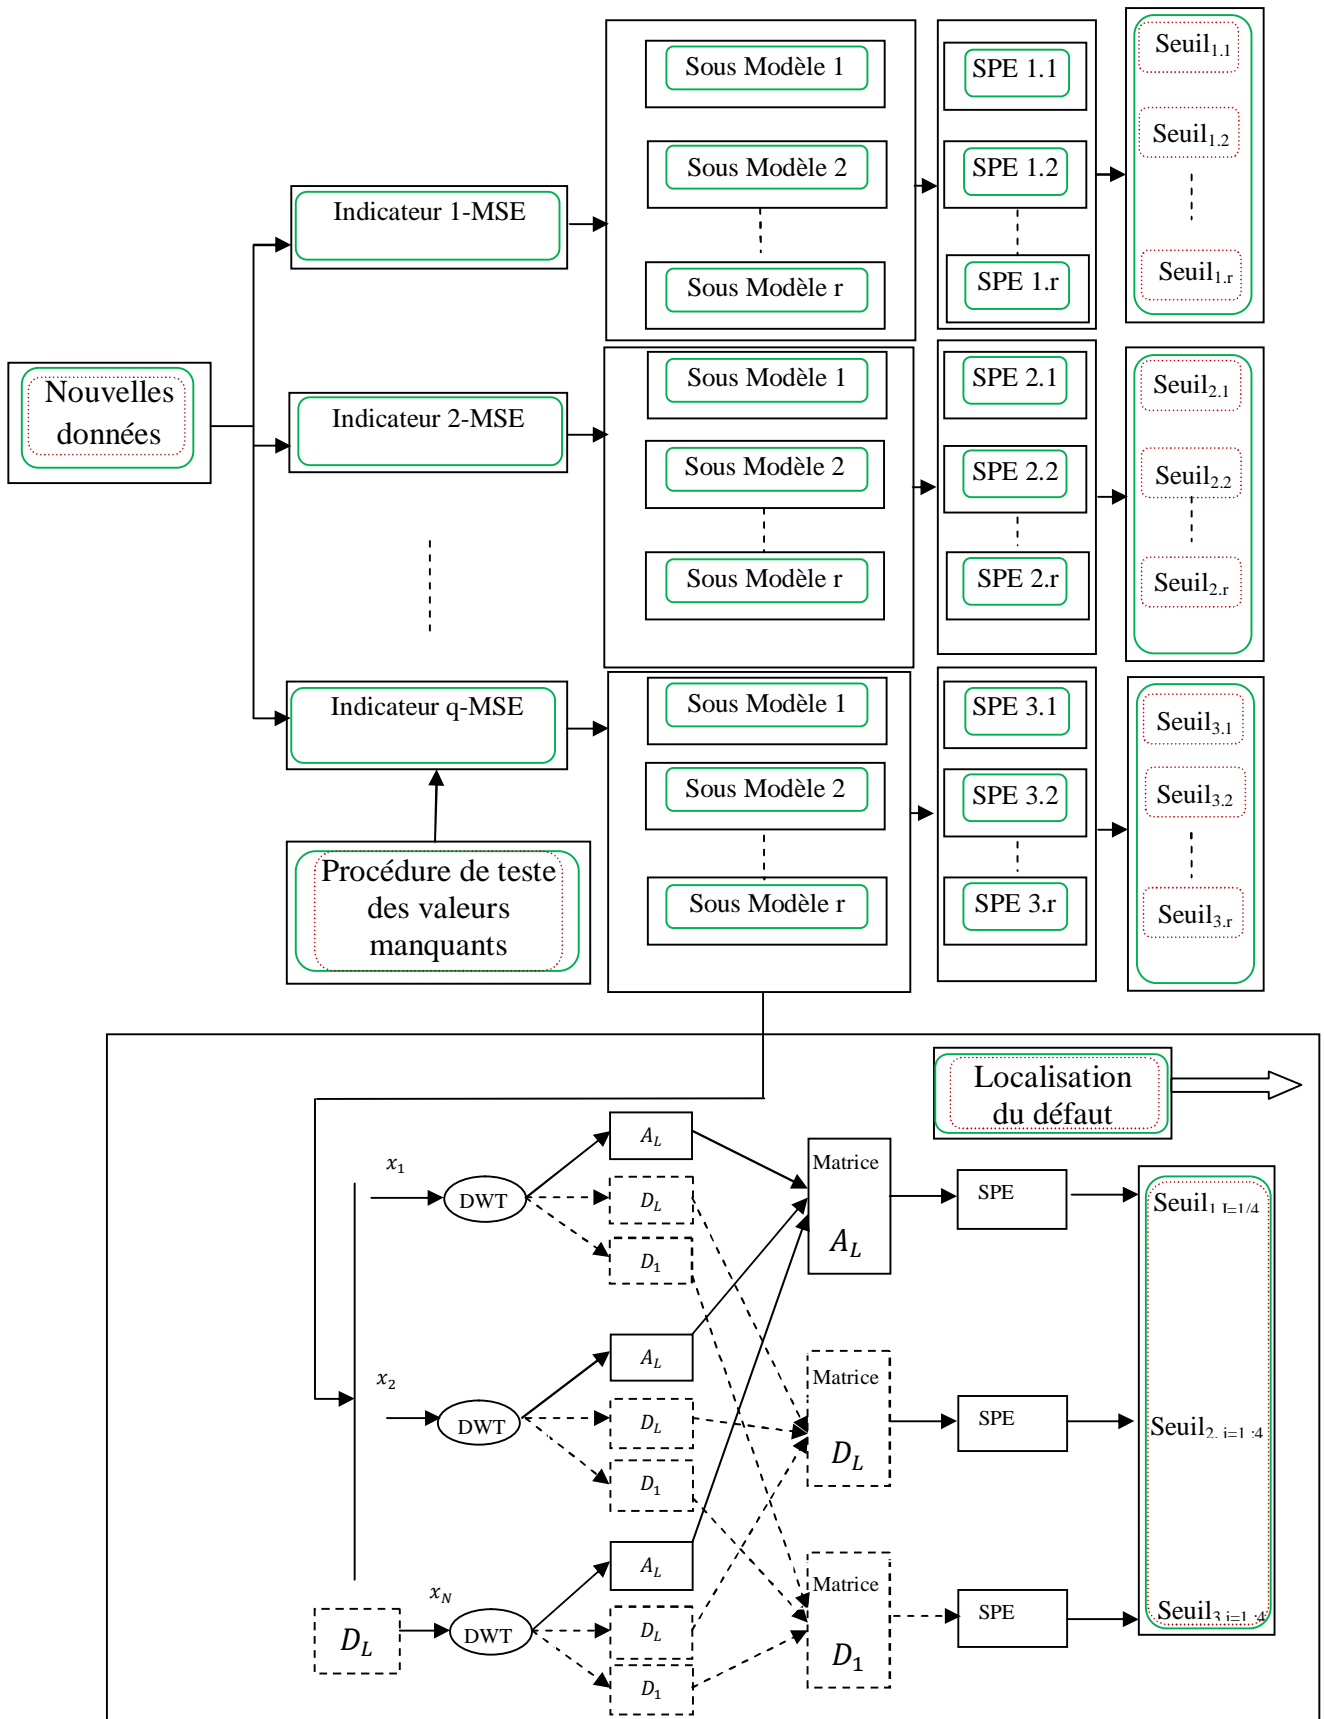


Figure 2.3- Procédure de détection par Multi-échelle-MSE-ACP.

2.5.1.2 Procédure de surveillance en ligne

Le test de détection et localisation peut s'effectuer en ligne comme indique la figure 2.3 :

- Calculer le SPE_i relatif au modèle MSE_ACP.
- Tracer l'évolution des composantes principales PC_i .
- Comparer l'indice SPE_i au seuil approprié $seuil_i$ et former la signature expérimentale du défaut [75].
- Calculer le SPE_i et T^2 relatif au modèle Multi-échelle MSE-ACP.
- Comparer l'indice SPE_j et T_j^2 au seuil approprié $seuil_{j-spe}$ et $seuil_{j-T^2}$ et former la signature expérimentale du défaut.
- Comparer le type d'ondelette mère utilisé de la dernière décomposition de Détail_i avec la segmentation de signal de la dernière composante PC_{der} .

Pratiquement, certains indices SPE_i relatifs au modèle ACP sont entachés des erreurs de modélisation et présentent des taux de fausses alarmes élevés. Pour optimiser la localisation de défauts, on a proposé une méthode de construction de modèles partiels à partir des calculs des indicateurs à travers MSE-ACP multi-échelle.

2.5.2 Méthode d'algorithme d'élimination

Algorithme d'élimination qui a été proposé par Stork fournit un progrès important par rapport aux méthodes antérieures dans sa capacité de détection et d'identification simultanées de capteurs [76]. Il consiste à calculer une nouvelle valeur de l'indice SPE après élimination de la ^{jème} variable de l'ensemble des variables à surveiller.

$$SPE_{-j} = X_{-j}^T (I_{m-1} - \hat{P}_{-j} \hat{P}_{-j}^T) X_{-j} \quad ; j = 1, 2, \dots, m \quad (2.50)$$

Où $X_{-j} \in R^{m-1}$ et la j ème variable éliminée X_{-j} est donnée par :

$$X_{-j} = T_{-j} P_{-j}^T + E_{-j} \quad (2.51)$$

A la fin de la première itération, on calcule pour chacun des m modèles une quantité désignée par $SPE_{ratio-j}$ entre la valeur SPE_{-j} et la limite $\delta_{\alpha,-j}^2$, elle est calculée comme suit :

$$SPE_{ratio-j} = \frac{SPE_{-j}}{\delta_{\alpha,-j}^2} \quad (2.52)$$

Le variable lorsqu'il est enlevé, génère le plus petit $SPE_{ratio-j}$ est jugé être influencé au maximum par une perturbation. Ce variable est déterminé comme non fiable et est définitivement retiré du nouvel échantillon et de l'ensemble de modèles.

Si le rapport $SPE_{min-ratio-j} < 1$, la procédure est arrêtée, car après avoir retiré ce capteur, les capteurs restants tombent dans la limite de contrôle prescrite pour l'espace modèle. Si le rapport $SPE_{min-ratio-j} > 1$, l'algorithme passe à la deuxième itération, où les $m - 1$ variables restantes sont éliminées séquentiellement. L'algorithme continue jusqu'à ce que le $SPE_{ratio-j}$ minimum pour une itération donnée soit inférieur à 1, ou que le nombre d'itérations dépasse une limite prédéfinie.

2.5.3 Méthode de reconstruction des résidus

Les résidus structurés sont conçus de façon à ce que chaque résidu réponde à un sous-ensemble distinctif de défauts et soit insensible aux autres. Avec des résidus structurés, le test de seuil est mis en œuvre séparément sur chaque composante de l'ensemble résiduel. Le résultat du test appliqué au résidu $r_i(k)$ est une variable binaire $\varepsilon_i(k)$ de sorte que [77]:

$$\varepsilon_i(k) = \begin{cases} 0, & \text{si } |r_i(k)| < k_i \\ 1, & \text{si } |r_i(k)| \geq k_i \end{cases} \quad i = 1, \dots, n \quad (2.53)$$

Le vecteur $\varepsilon_i = [\varepsilon_1 \varepsilon_2 \dots \varepsilon_n]^T$ est la signature de défaut, la localisation de défauts était faite par la comparaison du code effectivement obtenu à un ensemble prédéfini de codes. Une structure «isole» si chaque colonne est différente et «fortement isolée» si les colonnes restent différentes des colonnes valides lorsque 1 sont transformées en 0. L'isolement fort est mieux réalisé par des structures canoniques de colonne, dans lesquelles chaque code de défaut a le même nombre de 0, chacun dans un modèle différent. Le tableau 2.1 est une structure canonique de colonne pour quatre défauts $\Delta x_1, \Delta x_2, \Delta x_3, \Delta x_4$ et quatre résidus r_1, r_2, r_3, r_4 .

	Δx_1	Δx_2	Δx_3	Δx_4
r_1	0	0	1	1
r_2	1	0	0	1
r_3	1	1	0	0
r	0	1	1	0

Table II.1 Exemple d'une matrice des signatures théoriques avec quatre résidus.

Les résidus structurés sont générés par l'équation suivante:

$$\begin{aligned} r(k) &= W\tilde{P}^T x(k) \\ &= W\tilde{P}^T (x^o(t) + \Delta(x, k) + \nabla(k - T_0)\phi(x, k)) \\ &= W(\tilde{t}^*(k) + \tilde{\nabla}(k - T_0)\phi(x, k)) \\ &= W(\tilde{t}^*(k) + \tilde{t}(k) - \tilde{t}^*(k)) \end{aligned}$$

$$= W\tilde{t}(k) \quad (2.54)$$

L'équation (2.54) décrit la relation entre le vecteur des résidus primaires $\tilde{t}(k)$ et le vecteur des résidus structurés $r(k)$, la i ème rangée de W , w_i^T est conçue de telle sorte que les zéros assignés pour la i ème ligne de la matrice de structure soient mis en œuvre, c'est-à-dire que le i -ème résidu soit découplé de tous les défauts apparaissant avec 0 dans cette rangée. Cela exige que:

$$w_i^T B^i = 0 \quad (2.55)$$

Où B^i est la matrice regroupant les colonnes de la matrice B correspondant à des zéros dans la i ème ligne de la matrice d'incidence. Le reste de la matrice B, B^i , devrait satisfaire:

$$w_i^T B^i = V_i^T \quad (2.56)$$

$$\begin{cases} \text{rang}(B^i) & \leq m - 1 \\ \text{rang}[B^i \ b^i] = \text{rang}(B^i) + 1 \end{cases} \quad (2.57)$$

(2.57) représente les deux conditions nécessaires et suffisantes qui doivent être vérifiées pour la localisation de défaut.

2.5.4 Méthode de reconstruction de variables

La qualité de reconstruction est attachée à la capacité du modèle ACP à modéliser les relations de redondance entre les variables, ce qui permet de déterminer le nombre de CPs exprimant une meilleure reconstruction [29]. La reconstruction d'un indice de détection de défaut le long d'une direction variable minimise l'effet de cette variable sur l'indice de direction [64].

Le vecteur de reconstruction $Z_i(k)$ et le vecteur de mesures $x(k)$ sont attachés par la relation:

$$Z_i(k) = x(k) - \nabla_i(k - T_0)\phi_{ir}(x, k) \quad (2.58)$$

Où $\phi_i(x, k) \in R^r$ est le vecteur des amplitudes des variations des mesures dues à un défaut.

La matrice orthogonale $\nabla_{ir}(k - T_0) \in R^{m \times r}$ montre les directions de reconstruction.

En général, l'indice de détection de défaut de la mesure reconstruite est:

$$\begin{aligned} \text{Index } Z_i(k) &= Z_i^T(k)M(k)Z_i(k) = \|Z_i(k)\|_M^2 \\ &= \|x(k) - \nabla_i(k - T_0)\phi_{ir}(x, k)\|_M^2 \end{aligned} \quad (2.59)$$

La tâche de la reconstruction est de trouver une $\phi_{ir}(x, k)$ sachant que $\text{Index } Z_i(k)$ est minimisé. Cette minimisation se fait en prenant la première dérivée de $\text{Index } Z_i(k)$ avec le respect de $\phi_{ir}(x, k)$ et l'égaliser à 0.

$$d(Index(Z_i(k)))/d\phi_{ir}(x, k) = -2(x(k) - \nabla_i(k - T_0)\phi_{ir}(x, k))^T M(k)\nabla_i(k - T_0) \quad (2.60)$$

Mettre (2.60) égal à 0, et résoudre pour $\phi_{ir}(x, k)$.

$$\phi_{ir}(x, k) = (\nabla_i^T(k - T_0)M(k)\nabla_i(k - T_0))^{-1}\nabla_i^T(k - T_0)M(k)x(k) \quad (2.61)$$

Afin d'assurer la reconstruction, il faut que la matrice $\nabla_i^T(k - T_0)M(k)\nabla_i(k - T_0)$ soit de plein rang colonne.

En remplaçant (2.61) dans (2.58), on trouve :

$$Z_i(k) = [I_K - \nabla_i(k - T_0)[(\nabla_i^T(k - T_0)M(k)\nabla_i(k - T_0))^{-1}]\nabla_i^T(k - T_0)M(k)]x(k) \quad (2.62)$$

Avec :

$$Q_i(k) = (\nabla_i^T(k - T_0)M(k)\nabla_i(k - T_0))^{-1}]\nabla_i^T(k - T_0)M(k) \quad (2.63)$$

On obtient donc l'expression suivante:

$$H_i(k) = I_K - \nabla_i(k - T_0)Q_i(k) \quad (2.64)$$

La matrice H_i possède la propriété suivante:

$$H_i(k)\nabla_i(k - T_0) = 0 \quad (2.65)$$

Et on peut écrire :

$$x(k) = \nabla_i(k - T_0)x_c(k) + \nabla_{\bar{i}}(k - T_0)x_{\bar{c}}(k) \quad (2.66)$$

Avec:

$$\begin{cases} x_c(k) = \nabla_i^T(k - T_0)x(k) & x_c(k) \in R^r \\ x_{\bar{c}}(k) = \nabla_{\bar{i}}^T(k - T_0)x(k) & x_{\bar{c}}(k) \in R^{m-r} \end{cases} \quad (2.67)$$

Indice	Valeurs de la matrice $M(k)$
$SPE(k)$	\tilde{C}
$T^2(k)$	$\hat{P}\hat{\Lambda}^{-1}\hat{P}^T$
$\varphi(k)$	\emptyset
$SWE(k)$	$\tilde{P}\tilde{\Lambda}^{-1}\tilde{P}^T$

Table II.2 Valeurs de la matrice $M(k)$ en fonction des indicateurs de détection de défauts.

Où $x_c(k)$ et $x_{\bar{c}}(k)$ sont respectivement correspondants aux r composantes de $x(k)$ à reconstruire et $m - r$ composantes restantes de $x(k)$. on peut conclure que à partir de (2.67) il est possible de générer un ensemble de résidus structurés insensibles à certaines variables.

En présence de la variation du vecteur de mesure due à un défaut $\phi_{ir}(x, k)$, l'erreur de reconstruction est donnée par:

$$x^*(k) - Z_i(k) = \nabla_i(k - T_0)\phi_{ir}(x, k) - \nabla_i(k - T_0)\phi_i(x, k) \quad (2.68)$$

En peut écrire encore :

$$\begin{aligned} x^*(k) &= I_m - \nabla_i(k - T_0)Q_i(k) - \nabla_i(k - T_0)Q_i(k)[x^*(k) - \nabla_i(k - T_0)\phi_i(x, k)] \\ &= I_m - \nabla_i(k - T_0)Q_i(k) - \nabla_i(k - T_0)Q_i(k) x^*(k) - \nabla_i(k - T_0)Q_i(k)\nabla_i(k - T_0)\phi_i(x, k) \\ &= Z_i(k) [I + \nabla_i(k - T_0)\phi_i(x, k)] + \nabla_i(k - T_0) Q_i(k) x^*(k) \\ x^*(k) - Z_i(k) &= \nabla_i(k - T_0) Q_i(k) x^*(k) \\ Z_i(k) &= [\nabla_i(k - T_0) Q_i(k) + I]x^*(k) \end{aligned} \quad (2.69)$$

2.6 Conclusion

Ce chapitre a été consacré à l'exposé des techniques de détection et de localisation dans le cadre d'une démarche de diagnostic par l'analyse en composantes principales linéaires. Cette dernière a pour objectif de rechercher à réduire l'espace de dimension de départ lors de la projection des données sur un autre espace avec une diminution minimale d'information. La modélisation par l'ACP permet de décrire les relations existantes entre les différents variables des mesures afin d'estimer le comportement des variables.

La détection de défauts est réalisée avec l'aide des indicateurs de détection reposant sur les deux espaces respectivement, résiduel et principal. Les indices les plus répandus dans la technique d'ACP sont les indices T^2 et SPE , cependant ce dernier est très sensible aux erreurs de modélisation. Dès lors on peut dire que c'est un test qui englobe les erreurs de chacun des résidus où existent des indicateurs de comportement des variables. L'indice T^2 ne peut être utile pour la détection de défauts à cause de difficulté d'interprétation des résultats obtenus avec ce dernier (elle est calculée à partir des 1^{er} PCs) surtout lorsqu'on utilise cet indice seul pour la détection. Pour cette raison nous avons proposé d'utiliser un nouvel indice basé sur les dernières PCs en conjonction avec des règles de détection.

Différentes approches de localisation ont été exposées, la localisation des variables est effectuée soit par:

- Structuration de résidus.
- Calcul des contributions de variables à l'indicateur de détection.

Premièrement nous avons présenté l'art des techniques de localisation avec structuration des résidus dans le cas d'ACP et avec conjointement des autres méthodes ainsi que des différentes approches offertes dans la littérature.

3

Filtre basé sur l'analyse d'entropie multi-échelle (MSE) & analyse en ondelettes

Sommaire

3.1	Introduction	43
3.2	Filtre basé sur l'Entropie multi-échelle (FME).....	44
3.3	SampEn par bloc (BSE).....	45
3.4	FME Pour Gaussien.....	46
3.5	FME pour 1/f de bruit.....	50
3.6	Application de l'analyse en d'ondelettes au cours de l'analyse MSE.....	50
3.7	Transformée en ondelettes continue.....	51
3.8	Ondelettes de Daubechies.....	51
3.9	La variance et l'entropie d'ondelettes.....	52
3.10	Théorie des paquets d'ondelettes.....	53
3.11	Conclusion.....	54

3.1 Introduction

Mesurer la complexité des signaux de sortie des systèmes complexes a attiré beaucoup d'attention ces dernières années. Des nombreuses techniques ont été développées [78], [79], parmi lesquelles l'entropie multi-échelles (MSE) proposée par Costa et al [80] a été appliquée avec succès dans de nombreux domaines.

Pincus a créé une famille de statistiques, appelée entropie approximative (ApEn) [81], visant à mesurer la régularité du signal, la présence de modèles similaires dans la série chronologique. L'entropie approximative est affectée par un effet de biais, ApEn dépend fortement de la longueur d'enregistrement. La corrélation de l'effet de biais n'est pas triviale, car le retrait direct de l'auto-comptage par l'atténuation peut engendrer une sensibilité élevée aux valeurs aberrantes. Richman et Moorman [82] ont démontré que dans certains cas ApEn manque de cohérence. Son calcul en séries chronologiques irrégulières est affecté par un biais, ce qui peut entraîner une surestimation de la valeur d'entropie, surtout lorsque les valeurs sont très faibles. Richman et Moorman [83] ont développé une modification de l'algorithme ApEn, nommée entropie d'échantillon (SampEn), cette dernière montre une cohérence relative dans les cas où ApEn ne le fait pas.

L'algorithme MSE calcule l'entropie d'échantillon (SampEn) sur la gamme des échelles pour représenter la complexité d'un temps séries. La procédure de calcul de MSE peut être résumée en deux étapes:

- Construire des séries temporelles grossières selon un facteur d'échelle τ .
- Calculer le SampEn de chaque série chronologique grossière.

Nous allons proposer une analyse d'entropie multi-échelle basée sur un filtre FME, ce qui a pour objectif la robustesse des données de différentes longueurs. L'étape majeure de l'analyse MSE est la procédure d'évaluation de taux d'entropie [84]. Cette dernière est obtenue par l'extraction des composantes de basse fréquence des séries temporelles, à différentes échelles. Cette procédure peut être réinterprétée du point de vue du filtre en appliquant un filtre passe-bas constant par morceaux qui présente une représentation matricielle de la série temporelle. Nous allons prendre ce point de vue dans l'étude de l'entropie multi-échelles basée sur le filtre. La série temporelle est passée à travers des matrices filtrantes à différentes échelles et une valeur d'entropie d'échantillons est calculée par blocs à chaque échelle. Ce qui permet d'une part, le réglage général qui donne une compréhension approfondie des MSE et d'autre part, il nous permettra de choisir un filtre qui s'adapte aux données pour améliorer le résultat d'entropie [85].

L'analyse MSE mesure la complexité d'une série temporelle à différentes échelles. Lorsque nous appliquons des MSE à la série de l'intervalle de MCSA, nous mesurons la complexité de la série chronologique en regardant les valeurs d'entropie à différentes échelles, ce qui nous indique quelle partie des signaux est plus complexe que d'autres à certaines échelles. Les valeurs d'entropie à différentes échelles peuvent également être utilisées comme caractéristiques extraites pour classer les différents cas d'études de l'engrenage de la boîte de vitesses par MCSA, en appliquant la classification par la méthode de clustering soustractif à des séries de temps d'intervalle MCSA et en utilisant les valeurs d'entropie de MSE.

L'analyse en ondelettes [86] nous fournit un moyen systématique de décomposer les séries temporelles originales en composantes de fréquence inférieure et supérieure. L'analyse multi-résolution en ondelettes est appliquée sur des indicateurs à travers l'analyse d'entropie multi-échelle. Nous décomposons la série chronologique d'origine en utilisant la transformée de paquets d'ondelettes à différentes échelles après le calcul de l'entropie de l'échantillon de chaque série temporelle filtrée.

3.2 Filtre basé sur l'Entropie multi-échelle (FME)

Pour rendre le MSE plus robuste aux signaux de nature différente, nous présentons le FME qui prendra en compte la complexité structurelle significative d'un système électro-énergétique sur des échelles temporelles résultant d'un filtre approprié pour un système spécifique. Nettement, à chaque échelle, la série temporelle est passée à travers un filtre désiré pour capturer son caractéristique [85].

La méthode de filtrage d'entropie à plusieurs échelles FME [87] Consiste à mesurer l'information h par rapport aux coefficients d'ondelettes, et de séparer celui-ci en deux parties h_s , et h_n . L'expression h_n est appelée l'information de signal et représente la partie de h qui n'est certainement pas contaminé par le bruit. L'expression h_s est appelée l'information de bruit et représente la partie de h qui peut être contaminée par le bruit. Nous avons:

$$h = h_s + h_n \quad (3.1)$$

Le coefficient corrigé $\tilde{\omega}$ devrait minimiser:

$$J(\tilde{\omega}_j) = h_s(\omega_j - \tilde{\omega}_j) + \alpha h_n(\tilde{\omega}_j) \quad (3.2)$$

Il existe un minimum d'informations dans le résidu $\omega - \tilde{\omega}$ Qui peut être due au signal significatif, et un minimum d'informations qui pourraient être dues au bruit dans la solution $\tilde{\omega}_j$. Afin de vérifier un certain nombre de propriétés, les fonctions suivantes ont été proposées pour h_s et h_n dans le cas du bruit Gaussien [88]:

$$h_s(\omega_j) = \frac{1}{\sigma_j^2} \int_0^{|\omega_j|} u \operatorname{erf} \left(\frac{|\omega_j| - u}{\sqrt{2}\sigma_j} \right) du \quad (3.3)$$

$$h_n(\omega_j) = \frac{1}{\sigma_j^2} \int_0^{|\omega_j|} u \operatorname{erf} \left(\frac{|\omega_j| - u}{\sqrt{2}\sigma_j} \right) du \quad (3.4)$$

L'entropie est dérivée en utilisant une modélisation du bruit contenu dans les données:

$$h(\omega_j) = \int_0^{|\omega_j|} P_n(|\omega_j| - u) \left(\frac{\partial h}{\partial x} \right)_{x=u} du \quad (3.5)$$

Où $P_n(\omega_j)$ est la probabilité que le coefficient ω_j peut être due au bruit.

$$P_n(\omega_j) = \operatorname{Prob}(W > |\omega_j|) \quad (3.6)$$

Pour le bruit Gaussien, nous avons:

$$P_n(\omega_j) = \frac{2}{\sqrt{2}\sigma_j} \int_{|\omega_j|}^{+\infty} \exp \left(\frac{-W^2}{2\sigma_j^2} \right) dW = \operatorname{erf} \left(\frac{|\omega_j|}{\sqrt{2}\sigma_j} \right) \quad (3.7)$$

3.3 SampEn par bloc (BSE)

L'entropie de l'échantillon SampEn par bloc (BSE) est appliquée pour la série temporelle filtrée y^τ pour chaque échelle [85]. L'adaptation de BSE à la taille des filtres utilisés dans FME, conduit à des signaux de sortie comportant des blocs constitués plus d'un composant. Le BSE pour les séries y^τ pour $\tau \geq 2$. Il suit la même idée que l'entropie de l'échantillon et est conçu pour convenir à la structure de y^τ .

Notez que y^τ consiste en n blocs, chacun d'entre eux ayant p_τ est obtenu à partir d'un bloc de x transformé par la même matrice A^τ . Les composants de chaque bloc représentent des informations de x , capturé par différentes lignes du filtre A^τ .

Le calcul de BSE considère chaque bloc de y^τ comme une seule unité et appliquer le processus de calcul de l'entropie y^τ :

$$y^\tau = [y_0^\tau, \dots, y_{n-1}^\tau] \quad (3.8)$$

Où y_i^τ est un vecteur avec p_τ composants:

$$[y_j^\tau]_s = y^\tau(j p_\tau + s) \quad (3.9)$$

Pour $s \in Z_{p_\tau}$ et avec $[d]_s$ désignant la $s^{\text{ème}}$ composante d'un vecteur d .

La séquence correspondant à u_m est l'entropie de l'échantillon est construite par :

$$u_m^\tau = \{u_m^\tau(j) : j \in Z_{n-m}\} \quad (3.10)$$

Où $u_m^\tau(j) = [y_{j+k}^\tau : k \in Z_m]$ consiste de m vecteurs.

$$\sigma_s(u_m^\tau(l), u_m^\tau(j)) = \max\{|[y_{l+k}^\tau]_s - [y_{j+k}^\tau]_s| : s \in Z_m\} \quad (3.11)$$

La distance entre $u_m^\tau(l)$ et $u_m^\tau(j)$ est définie par:

$$d(u_m^\tau(l), u_m^\tau(j)) = [\sigma_s(u_m^\tau(l), u_m^\tau(j)) : s \in Z_{p_\tau}] \quad (3.12)$$

Pour un $u_m^\tau(l)$, désigne par $B_l^{m,\tau}$ le nombre de vecteurs $u_m^\tau(j)$ avec $j > l$ qui satisfont :

$$\sigma_s(u_m^\tau(l), u_m^\tau(j)) < r_s^\tau \quad (3.13)$$

Pour chaque $s \in Z_{p\tau}$, où:

$$r_s^\tau = \sum_{t=1}^q |A_{st}^\tau| r \quad (3.14)$$

Avec r est la tolérance utilisée pour calculer l'entropie de l'échantillon de x et A_{st}^τ est le (s, t) – l'entropie de A^τ . On a :

$$r^\tau = [r_0^\tau, r_1^\tau, \dots, r_{p^\tau-1}^\tau] \quad (3.15)$$

et :

$$\tilde{C}_l^m(y^\tau, r^\tau) = \frac{B_l^{m,\tau}}{n-m+1}, l \in Z_{n-m+1} \quad (3.16)$$

BSE $\tilde{S}_m(y^\tau, r^\tau)$ de y^τ est défini de la même manière que l'entropie d'échantillon avec $C_l^m(x, r)$ remplacé par $\tilde{C}_l^m(y^\tau, r^\tau)$. Et on a :

$$\tilde{S}_m(y^\tau, r^\tau) = -\ln \left[\frac{\tilde{C}_l^{m+1}(y^\tau, r)}{\tilde{C}_l^m(y^\tau, r)} \right] \quad (3.17)$$

Il existe une relation entre MSE et FME. Par MSE, la série $\{y^\tau\}$ est construite selon l'équation:

$$y_j^{(\tau)} = 1/\tau \sum_{i=(j-1)\tau+1}^{j\tau} x(i), j \in Z_{N/\tau} \quad (3.18)$$

La série filtrée est donnée par:

$$C^\tau = \left[\frac{1}{\tau}, \frac{1}{\tau}, \dots, \frac{1}{\tau} \right] \quad (3.19)$$

À l'échelle τ en peut écrire :

$$y^\tau = \left(I_{\lfloor \frac{N}{\tau} \rfloor} \otimes C^\tau \right) x \quad (3.20)$$

Ainsi y^τ a $\lfloor \frac{N}{\tau} \rfloor$ blocs ayant chacun une composante, dans ce cas, BSE dégénère à l'entropie standard de l'échantillon. Donc, MSE est un cas particulier de FME avec le filtre constant par morceaux C^τ à l'échelle τ .

3.4 FME pour Gaussien :

L'analyse du bruit Gaussien repose principalement sur les propriétés statistiques de la combinaison linéaire de variables aléatoires Gaussiennes. Nous allons considérer une simple forme Gaussienne pour $P(\{y_i\})$ appliquer à un signal 1 D [89]:

$$P_{\text{Gauss}}(\{y_i\}) = \frac{1}{Z_{\text{Gauss}}} \exp \left(-\frac{1}{2} \sum_{ij} y_i g_{ij}^{-1} y_j \right) \quad (3.21)$$

Où $Z_{\text{Gauss}} = (2\pi)^{p\tau/2} |g_{ij}|^{1/2}$

$$Z_{\text{Gauss}} = \int \prod_{i=1}^N dy_i \exp \left(-\frac{1}{2} \sum_{ij} y_i g_{ij}^{-1} y_j \right) \quad (3.22)$$

Le signal est caractérisé par la fonction de corrélation g_{ij} . Et le signal original est caractérisé par la distribution $P^{(\tau)}$. Nous avons:

$$Q^{(\tau)}\left(\{k_i\}, 1 < i < \frac{N}{\tau}\right) = \int \prod_{i=1}^{N/\tau} dy_i \exp\left(ik_i y_i^{(\tau)}\right) P^{(\tau)}\left(\{y_i^{(\tau)}\}, 1 < i < N/\tau\right) \quad (3.23)$$

Dans le cas Gaussien, la fonction caractéristique $Q^{(1)}(\{k_i\})$ prend une forme particulièrement simple :

$$Q_{Gauss}^{(1)}\left(\{k_i\}, 1 < i < \frac{N}{\tau}\right) = \exp\left(-\frac{1}{2} \sum_{ij} k_i g_{ij}^{(1)} k_j\right) \quad (3.24)$$

et:

$$Q_{Gauss}^{(\tau)}\left(\{k_i\}, 1 < i < \frac{N}{\tau}\right) = \exp\left(-\frac{1}{2} \sum_{ij}^{N/\tau} k_i g_{ij}^{(\tau)} k_j\right) \quad (3.25)$$

Lorsque la fonction de corrélation à l'échelle $g_{ij}^{(\tau)}$ est donné par:

$$g_{ij}^{(\tau)} = \frac{1}{\tau^2} \sum_{m=(i-1)\tau+1}^{i\tau} \sum_{n=(j-1)\tau+1}^{j\tau} g_{mn}^{(1)}, \quad 1 < i, j < N/\tau \quad (3.26)$$

La transformée de Fourier est donnée par:

$$y^{(\tau)} = \left(\frac{\tau}{N}\right)^{1/2} \sum_k \exp(ikl) y^{(\tau)}(k) \quad (3.27)$$

$$g_{mn}^{(\tau)} = \frac{\tau}{N} \sum_k \exp(ik(m-n)) g^{(\tau)}(k) \quad (3.28)$$

et:

$$(g_{mn}^{(\tau)})^{-1} = \frac{\tau}{N} \sum_k \exp(ik(m-n)) g^{(\tau)}(k)^{-1} \quad (3.29)$$

où $k = 2\pi\tau n/N$ et $n = 1, \dots, N/\tau$, nous obtenons donc:

$$y^{(\tau)}(k)^* = (y^{(\tau)}(-k)) \quad (3.30)$$

L'entropie $y^{(\tau)}$ prend une forme simple et nous trouvons:

$$y^{(\tau)} = \frac{1}{2} \sum_k \{1 + \log[2\pi g^{(\tau)}(k)]\} \quad (3.31)$$

Nous avons pour la distribution de probabilité:

$$P^{(\tau)} = \frac{1}{Z^{(\tau)}} \exp\left[-\frac{1}{2} \sum_k k |y^{(\tau)}(k)|^2 g^{(\tau)}(k)^{-1}\right] \quad (3.32)$$

$$Z^{(\tau)} = \int \prod_k dy^{(\tau)}(k) \exp\left[-\frac{1}{2} \sum_k k |y^{(\tau)}(k)|^2 g^{(\tau)}(k)^{-1}\right] \quad (3.33)$$

Pour l'entropie:

$$y^{(\tau)} = \frac{1}{2} \left(\frac{N}{\tau}\right)^d \left(1 + \log 2\pi - d \log \tau\right) + \frac{1}{2} \sum_k \log g^{(1)}\left(\frac{k}{\tau}\right) \quad (3.34)$$

La mesure d'entropie du bruit blanc Gaussien diminue lorsque l'échelle augmente avec les choix appropriés du filtre. Cela indique le manque de complexité du bruit blanc gaussien.

Pour une valeur donnée de $r > 0$:

$$r_s^\tau = \sum_{t=1}^{q\tau} \left| A_{st}^{(\tau)} \right| r, \quad s \in Z_{p\tau}^+ \quad (3.35)$$

Et pour un vecteur donné $y \in R^{p\tau}$:

$$\Omega_y = ([y]_1 - r_1^\tau [y]_1 + r_1^\tau) \times \dots \times ([y]_{p\tau} - r_{p\tau}^\tau [y]_{p\tau} + r_{p\tau}^\tau) \quad (3.36)$$

Pour l'écart-type δ de g_i , la matrice $g_{ij} \in R^{p\tau \times p\tau}$ est donnée par:

$$g_{ij \delta, t} = \sum_{j=1}^{p\tau} A_{sj}^{(\tau)} A_{tj}^{(\tau)} \delta^2, \quad 1 \leq s, t \leq p\tau \quad (3.37)$$

$$I(\Omega_y) = \int_{\Omega_y} \lambda_{g_{ij}} \exp\left(-\frac{1}{2} y_i^T g_{ij}^{-1} y_i\right) dy_i \quad (3.38)$$

$$\xi_m(g^\tau, r^\tau) = -\ln \left\{ \int_{R^{p\tau}} I(\Omega_y) \lambda_{g_{ij}} \exp\left(-\frac{1}{2} y_i^T g_{ij}^{-1} y_i\right) dy_i \right\} \quad (3.39)$$

La formule (3.39) c'est l'écriture de la matrice de filtre générale C^τ .

Les dérivations analytiques détaillées de MSE pour les deux cas particuliers: bruits corrélés et non corrélés avec des distributions Gaussiennes. Pour le cas de bruit non corrélée, et pour $m = 1$, la probabilité conditionnelle que la distance entre deux points de données soit inférieure ou égale à r :

$$|y_i - y_j| \leq r \quad (3.40)$$

Étant donné que la distance entre les deux points de données précédents est également inférieure ou égal à r si :

$$|y_{i-1} - y_{j-1}| \leq r \quad (3.41)$$

La probabilité conjointe d'une suite finie de variables aléatoires indépendantes est donnée par :

$$P(y_1, y_2, \dots, y_n) = \prod_{i=1}^n P(y_i) \quad (3.42)$$

et :

$$\begin{aligned} P_r(|y_i - y_j| \leq r, |y_{i-1} - y_{j-1}| \leq r) &= \frac{P_r(|y_i - y_j| \leq r \wedge |y_{i-1} - y_{j-1}| \leq r)}{P_r(|y_{i-1} - y_{j-1}| \leq r)} \\ &= \frac{P_r(|y_i - y_j| \leq r \times |y_{i-1} - y_{j-1}| \leq r)}{P_r(|y_{i-1} - y_{j-1}| \leq r)} \\ &= P_r(|y_i - y_j| \leq r) \end{aligned} \quad (3.43)$$

Le résultat de (3.43) est valable pour toute valeur m , chaque fois que les variables sont indépendantes. Donc la probabilité conditionnelle est donnée par :

$$S_E = -\ln P_r(|y_i - y_j| \leq r) \quad (3.44)$$

Pour une valeur donnée de \hat{y} , la probabilité de trouver d'autres points de données dans la distance r de \hat{y} est donnée par :

$$P_r(|\hat{y} - y| \leq r) = \int_{\hat{y}-r}^{\hat{y}+r} P(y) dy \quad (3.45)$$




Figure 3.1 Distribution Gaussienne. Les zones ombrées centrées aux points -2 et 1 représentent la probabilité que les distances entre chacun de ces points et tout autre point choisi au hasard parmi les séries chronologiques soient inférieures ou égales à r .

La figure 3.1 montre que si $y_j = 1$ et $r = 0.3$ on a $P_r(|1 - y_j| \leq 0.3)$ est la zone sous la courbe gaussienne entre les lignes verticales $y = 0.7$ et $y = 1.3$. donc y_j peut prendre toute valeur entre $-\infty$ et $+\infty$. On peut écrire encore :

$$\begin{aligned} P_r(|y_i - y_j| \leq r) &= \int_{-\infty}^{+\infty} \left\{ \int_{y_i-r}^{y_i+r} P(y_i) dy_i \right\} P(y_i) dy_i \\ &= \frac{1}{2\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} \left\{ \int_{y_i-r}^{y_i+r} \exp\left(\frac{-y_i^2}{2\sigma^2}\right) dy_i \right\} \exp\left(\frac{-y_i^2}{2\sigma^2}\right) dy_i \quad (3.46) \end{aligned}$$

Et

$$\sigma_\tau = \frac{\sigma}{\sqrt{\tau}} \quad (3.47)$$

Où σ_τ la variance des séries temporelles correspondant à l'échelle τ , et σ représente la variance de la série initiale.

3.5 FME pour 1/f de bruit:

1 / f de bruit, est le bruit dominant pour les appareils CMOS, BJT, FET et HBT sub-micron profond. Il peut avoir un impact significatif sur les performances des circuits analogiques (RF) et provoque des instabilités dans les signaux. 1/f de bruit est caractérisé par une densité spectrale de puissance non uniforme, avec un excès de type 1/f dans la partie basse fréquence du spectre [90] [91].

Afin d'analyser les performances de la FME, Valencia et al [92] a traité un processus totalement imprévisible (bruit blanc gaussien) et un signal à corrélation à longue portée (bruit 1/f). Ils ont signalé que le FME est plat avec le facteur d'échelle τ pour le bruit blanc gaussien et présente une augmentation lente mais progressive avec le facteur d'échelle τ dans le cas du bruit 1/f. L'aliasing est plus significatif à des échelles courtes lorsque les oscillations rapides sont dominantes, les plus grandes différences entre FME et les algorithmes MSE originaux se trouvent en présence d'oscillations à haute fréquence [93].

Le calcul numérique de la matrice de covariance, exige la limitation de la gamme de fréquences de la densité spectrale de puissance $S(\omega)$, du 1/f signal de bruit :

$$S(\omega) = \begin{cases} \frac{K}{\omega}, & \text{pour } \omega_1 \leq \omega \leq \omega_2 \\ 0, & \text{autrement} \end{cases} \quad \text{avec } K \text{ constant} \quad (3.48)$$

La fonction d'autocorrélation s'écrit par :

$$\phi(\tau) = \frac{K}{2\pi} \left\{ \ln \left(\frac{\omega_2}{\omega_1} \right) + \sum_{k=1}^{+\infty} \frac{(-1)^k}{(2k)!2k} \times [(\omega_2\tau)^{2k} - (\omega_1\tau)^{2k}] \right\} \quad (3.49)$$

3.6 Application de l'analyse en d'ondelettes au cours de l'analyse MSE

Dans cette partie, nous introduisons l'analyse en ondelettes sur MSE. La transformée d'ondelettes extrait les composantes de fréquence inférieure et supérieure du signal original à différentes échelles. Ainsi, nous pouvons examiner la complexité des composantes de fréquence inférieure et supérieure du signal à différentes échelles par la décomposition d'ondelettes aux signaux filtrés obtenus à partir de MSE. Les détails et les approximations sont calculés à partir de l'analyse multi-résolution en ondelettes de signal obtenu à partir de l'application de MSE. Basé sur des filtres à des Ondelettes de types Daubechies. Le processus de décomposition peut être réitéré, avec des approximations successives étant décomposées alternativement, de sorte qu'un signal soit décomposé en beaucoup de composants de hautes résolutions. Dans la pratique, on choisira un nombre approprié de niveaux basés sur la nature du signal à décomposer, ou sur un critère approprié.

3.7 Transformée en ondelettes continue

Les bases d'ondelettes révèlent la régularité du signal par l'amplitude des coefficients, et leur structure conduit à un algorithme rapide de calcul. Une base en ondelettes définit une représentation éparsée de signaux réguliers par morceaux, qui peuvent comprendre des transitoires et des singularités [94]. La transformée en ondelettes remplace les sinusoides de la transformée de Fourier par une famille de translations et de dilatations d'une même fonction appelée ondelette. Mathématiquement, la famille d'ondelettes se met sous la forme [95] :

$$\psi_{Ty}(a, b) = |a|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} y(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt \quad (3.50)$$

Où $\psi(t)$ représente la fonction ondelette mère, et $\overline{\psi}$ représente le conjugué complexe de $\psi(t)$ et $a, b \in R$ avec $a \neq 0$. a paramètre d'échelle ou dilatation et b paramètre de translation.

A partir de l'équation (3.50) l'expression dérivée de domaine de fréquence de la fonction de corrélation est obtenue:

$$\psi_{Ty}(a, b) = \frac{\sqrt{a}}{2\pi} \int_{-\infty}^{+\infty} Y(\omega) \overline{\hat{\psi}_a(\omega)} e^{j\omega b} d\omega \quad (3.51)$$

Où $\overline{\hat{\psi}_a(\omega)}$ est l'expression du domaine fréquentiel de $\overline{\psi\left(\frac{t}{a}\right)}$, et $Y(\omega)$ est l'expression du domaine fréquentiel de $y(t)$. La fréquence centrale est donnée par:

$$\omega_a = \frac{\omega_0}{a} \quad (3.52)$$

Où ω_0 est la fréquence centrale de $\hat{\psi}(\omega)$, et ω_a est le centre de fréquence de $\hat{\psi}_a(\omega)$.

3.8 Ondelettes de Daubechies

Les transformées d'ondelettes de Daubechies permettent de calculer des moyennes et des différences courantes par l'intermédiaire de produits scalaires avec des signaux d'échelle et des ondelettes. Elles nous fournissent un ensemble d'outils puissants pour effectuer des tâches de traitement de signal [96].

Pour $N \in \mathbb{N}$, l(ondelettes de Daubechies de classe D-2N est une fonction $\psi = \psi \in L^2(R)$ défini par :

$$\psi(y) = \sqrt{2} \sum_{k=0}^{2N-1} (-1)^k h_{2N-1-k} \varphi(2y - k) \quad (3.53)$$

où $h_0, \dots, h_{2N-1} \in R$ sont les coefficients de filtre constants qui satisfont aux conditions :

$$\sum_{k=0}^{N-1} h_{2k} = \frac{1}{\sqrt{2}} = \sum_{k=0}^{N-1} h_{2k+1} \quad (3.54)$$

pour $l=0,1,\dots, N-1$,

$$\sum_{k=2l}^{2N-1+2l} h_k h_{k-2l} = \begin{cases} 1 & \text{si } l = 0 \\ 0 & \text{si } l \neq 0 \end{cases} \quad (3.55)$$

Où la fonction d'échelle Daubechies est donnée par l'équation de récurrence suivante :

$$\varphi(y) = \sqrt{2} \sum_{k=0}^{2N-1} h_k \varphi(2y - k) \quad (3.56)$$

$$\varphi(y) = 0 \quad \text{pour } y \in R /]0, 2N - 1[$$

aussi bien que :

$$\int_R \varphi(2y - l) \varphi(2y - l) dy = 0 \quad \text{pour } k \neq l \quad (3.57)$$

En cherche à construire les ondelettes de Daubechies est la détermination du coefficient h_0, \dots, h_{2N-1} qui admettent une fonction de mise à l'échelle non-évolutive φ satisfaisant l'équation (3.56), et avec l'équation (3.54) cela donne en total $N + 2$ équations pour $2N$ coefficients de filtre h_k .

3.9 La variance et l'entropie d'ondelettes

Les ondelettes peuvent décomposer le signal original en composantes de différentes échelles, Par conséquent, il fournit un outil puissant pour détecter le modèle de variations à travers les échelles dans les données observées. La variance en ondelettes est calculée de sorte que différents ensembles de données peuvent être comparés à différentes échelles. Il est défini par [97]:

$$V(a) = \frac{1}{n} \sum_{j=1}^n \psi^2(a, y_i) \quad (3.58)$$

où $\psi^2(a, y_i)$ est le coefficient d'ondelettes carré associé à l'échelle a au point de données y_i et n est le nombre des points de données. La formule (3.58) est utilisée pour calculer l'ondelette Variance pour les différentes régions.

L'entropie est une mesure de l'incertitude, c'est une mesure du désordre ou du hasard dans un système. L'entropie donnée par Shannon est donnée par:

$$\psi S^k = - \sum P_j^{(k)} \log_2 P_j^{(k)} \quad (3.59)$$

Où $P_j^{(k)}$ est le coefficient d'ondelette pour chaque niveau k . La valeur de k dépend du niveau utilisé pour les différentes ondelettes utilisées. Ceci est utilisé pour calculer les valeurs d'entropie.

L'équation d'entropie pour chaque j lorsqu'en utilisant l'expansion de la série de Taylor pour $\ln P$ dans le voisinage de $a = 1$, est donné par:

$$\begin{aligned} - \sum P \ln P &= - \sum P \left(\frac{\ln P}{\ln 2} \right) = \frac{1}{\ln 2} \sum P \ln P \\ &= \frac{1}{\ln 2} \sum P \left(-\frac{5}{3} + \frac{5P}{3} - P^2 + \frac{P^3}{6} + \dots \right) = \sum (k_1 P - k_2 P^2 + k_3 P^3 - \dots) \end{aligned} \quad (3.60)$$

3.10 Théorie des paquets d'ondelettes

La transformation de paquets d'ondelettes fournit une méthode plus précise sur le traitement du signal [98]. Une autre décomposition de la partie haute fréquence est réalisée par transformée en paquets d'ondelettes selon la caractéristique du signal, la transformée de paquets d'ondelettes peut sélectionner de façon adaptative la bande de fréquence appropriée pour correspondre au spectre du signal et augmenter la résolution temps-fréquence. Le paquet d'ondelettes passe par la construction d'un nouvel espace U_j^n en combinant le sous-espace d'échelle V_j avec sous-espace ondelettes ψ_j . On peut écrire :

$U_j^0 = V_j$ et $U_j^1 = \psi_j$ avec $j \in Z$, et les relations de décompositions s'écrivent sous la forme :

$$U_{j+1}^0 = U_j^0 + U_j^1 \quad (3.61)$$

Avec $\varphi(y)$ et $\psi(y)$ sont respectivement, la fonction d'échelle orthogonale et la fonction d'ondelettes qui définissent par :

$$\begin{cases} \mu_0(y) = \varphi(y) \\ \mu_1(y) = \psi(y) \end{cases} \quad (3.62)$$

Et on a :

$$\begin{cases} u_{2n}(t) = \sqrt{2} \sum_{k \in Z} h(k) u_n(2t - k) \\ u_{2n+1}(y) = \sqrt{2} \sum_{k \in Z} g(k) u_n(2t - k) \end{cases} \quad (3.63)$$

Où $g(k) = (-1)^k h(1 - k)$.

Lorsqu'en $n = 0$, l'équation (3.63) s'écrivent :

$$\begin{cases} u_0(t) = \sqrt{2} \sum_{k \in Z} h(k) u_0(2t - k) \\ u_1(y) = \sqrt{2} \sum_{k \in Z} g(k) u_0(2t - k) \end{cases} \quad (3.64)$$

Dans l'analyse multi-résolution, $\varphi(y)$ et $\psi(y)$ répondent aux équations à deux échelles:

$$\begin{cases} \varphi(t) = \sqrt{2} \sum_{k \in Z} h_k \varphi(2t - k) & \{h_k\} \in l^2 \\ \psi(t) = \sqrt{2} \sum_{k \in Z} g_k \psi(2t - k) & \{g_k\} \in l^2 \end{cases} \quad (3.65)$$

L'algorithme de décomposition des paquets d'ondelettes peut être représenté sous la forme:

$$\begin{cases} d_l^{j,2n} = \sqrt{2} \sum_{k \in Z} a_{k-2l} d_k^{j+1,n} \\ d_l^{j,2n+1} = \sqrt{2} \sum_{k \in Z} b_{k-2l} d_k^{j+1,n} \end{cases} \quad (3.66)$$

Lorsque l'échelle augmente, les fonctions de base d'ondelettes orthogonales ont une résolution de fréquence inférieure, qui est le défaut de l'ondelette orthogonale. Le paquet d'ondelettes peut effectuer une segmentation supplémentaire de la bande de fréquence en augmentant la résolution de fréquence.

3.11 Conclusion

L'utilisation de l'entropie multi-échelle MSE pour explorer la complexité des systèmes électro-énergétiques a d'abord été étudiée dans plusieurs littératures. Via l'analyse MSE, il existe d'importantes oscillations, qui affectent l'analyse MSE pour les séquences MCSA dans les différents cas d'études dans notre moteur réducteur. Cette observation nous la décrivons plus en profondeur dans l'analyse multi-résolution en ondelettes qui a été proposée dans le but de diagnostic des systèmes électro-énergétiques, en filtrant le bruit aléatoire et les autres composantes de la machine pour n'avoir uniquement que la signature de défaut. L'analyse en MSE avec l'analyse en ondelettes grâce à ses grandes propriétés, semble être la plus intéressante à appliquer. En effet, son pouvoir d'extraire les informations et les décompositions des signaux, nous ont incités à l'adapter pour l'analyse des signaux des systèmes. Le diagnostic est basé sur l'analyse des signaux à niveau élevé obtenus à partir de la décomposition en ondelettes du signal. L'approche est concentrée sur l'étude des signaux d'approximation et de détail résultants de la décomposition qui contiennent les informations de défaut.

4

Développement d'une stratégie de diagnostic & application sur des processus réels

Première Partie : Diagnostic des défauts d'une boîte de vitesses à 3 étages entraînée par une Machine à induction par différentes techniques : l'entropie multi-échelle (MSE), statistique multivariée et les Ondelettes

Sommaire

4.1	Introduction	56
4.2	Présentation du système expérimental	58
4.3	La méthodologie et les techniques proposées de diagnostic des défaillances	60
4.4	Influence des défaillances dans des différents cas d'études sur MCSA.....	62
4.4.1	Influence des défaillances sur les grandeurs triphasées	62
4.4.2	Influence des défaillances sur l'analyse en composantes principales.....	64
4.5	Détection des défaillances d'engrenage basée sur l'analyse spectrale.....	65
4.6	Effet mécanique de la boîte de vitesses dans MCSA.....	68
4.7	L'équation mathématique du MCSA avec la prise en charge de réducteur 3 étages..	69
4.8	Application de la technique d'entropie multi-échelle MSE au diagnostic.....	72
4.9	Application de la technique des ondelettes au diagnostic.....	76
4.10	Détection des défaillances en utilisant des indices de détection	80
4.10.1	Erreur de prédiction au carré <i>SPE</i>	80
4.10.2	Statistique T2 de Hotelling	80
4.11	Conclusions.....	85
	ANNEXE.....	86

4.1 Introduction

La surveillance des réducteurs est considérée comme une fonction stratégique dans des nombreuses applications industrielles. Le diagnostic et la détection précoce des défaillances des dents est crucial pour optimiser la maintenance et de réduire l'impact financier des dommages aux dents. Dans ce contexte, le diagnostic des défaillances des réducteurs a été fondé sur l'analyse des signaux de vibration en raison du comportement des événements périodiques dans le système mécanique [99]. Ce comportement sera changé en cas d'une quelconque anomalie mécanique [100]. Cela est la raison pour laquelle les signaux de vibration ont montré des résultats satisfaisants et sont applicables dans les usines industrielles [101].

Les réducteurs sont des composantes des machines importantes dans un état de surveillance, qui sont utilisés pour la transmission de la puissance, de mouvement ou les deux. Sous une puissance accrue et des vitesses plus élevées, les défaillances tribologiques tels que le grippage, piqûres, usure légère, les dommages de surface et la rupture de dent sont des préoccupations majeures [102]. Quand un défaut d'engrenage local, tel qu'une fissure de dent se produit, le signal de vibration dans une révolution complète sera modifié par les effets d'un impact de courte durée à un niveau relativement faible d'énergie [103]. Les amplitudes correspondantes des pics dans le spectre de puissance augmentent ainsi que le nombre et l'amplitude des bandes latérales [104]. Cependant, l'analyse spectrale peut ne pas être capable de détecter les défaillances des réducteurs dans le cas des défauts locaux. Ce qui affecte principalement les bandes latérales en raison de la difficulté d'évaluer l'espacement et l'évolution des familles des bandes latérales dans le spectre. L'aspect des impacts mécaniques est associé à la résonance de la structure mécanique excitée par le défaut localisé de dent lorsque la dent endommagée est engagée [105]. De nombreuses approches pour détecter des défaillances dans les réducteurs ont été développées dont l'une est l'analyse du signal de vibration et des signaux acoustiques, qui sont utilisés pour détecter les défaillances naissants dans une boîte de vitesse [106-108]. La vitesse de rotation et les conditions de charge sont les deux paramètres importants pour affecter le niveau de vibration dans les réducteurs [109,110]. D'autres paramètres importants qui affectent le niveau de vibration comprennent: les défaillances dentaires tels que la déformation, la rupture ou la fracture de la dent [111,112]. Bien que l'utilisation importante de ces approches pour la surveillance de l'état et de la détection des défaillances d'engrenages, elles présentent de nombreux inconvénients, notamment le coût élevé, l'inaccessibilité du montage des transducteurs de vibrations et la sensibilité à l'emplacement d'installation [113]. L'adaptation de l'analyse de la signature

électrique de la machine pour la surveillance à distance des réducteurs a montré un grand succès afin d'évaluer l'état des composants [114]. Les analyses de signature Courant moteur (MCSA) représentent un tel exemple de détection des défauts des engrenages et fournissent des informations concernant la dynamique de torsion de l'équipement tournant [115,116]. Certaines recherches récentes ont abordé les couplages motoréducteurs et influence des défaillances dentaires sur les signaux électriques dans le moteur [109]. Le MCSA offre des avantages significatifs par rapport à l'analyse des vibrations en raison de son coût efficace et de sa mesure facile [118]. Mais la comparaison entre les résultats d'analyse du MCSA et ceux dérivés des vibrations traditionnelles montre que le courant est aussi important que la vibration en indiquant la présence des défaillances [119].

Dans ce chapitre, on concentre sur des études expérimentales de détection des anomalies affectant les engrenages. Il se compose d'un équipement industriel typique d'un moteur à induction entraînant une boîte de vitesses à 3 étages parallèle avec dentures hélicoïdales. Nous avons utilisé l'analyse spectrale de la transformée de Fourier rapide (FFT) des courants de phases des stators en conjonction avec la nouvelle approche de l'analyse de la signature de défaut basée sur l'application de entropie multi-échelle (MSE) et l'analyse des composantes principales (ACP). L'entropie multi-échelle (MSE) se réfère au calcul des entropies à travers une séquence d'échelles [120], qui tient compte non seulement la non-linéarité dynamique, mais aussi des effets d'interaction et de couplage entre les composantes mécaniques, fournissant ainsi beaucoup plus d'informations concernant le conditionnement des engrenages transmissions entraînées par des machines à induction. Après l'extraction des caractéristiques avec MSE, un classificateur est alors exécuté pour déterminer l'état à partir duquel le système fonctionne à l'aide des fonctionnalités extraites de MCSA. Les MSE à travers 20 échelles sont calculées pour former un ensemble de caractéristiques contenant des informations riches en indication de condition. Ensuite, quatre paramètres sont extraits de l'ensemble de caractéristiques d'origine afin de réduire la dimensionnalité de la variable d'entrée du classificateur, qui sont : la valeur maximale, la valeur moyenne arithmétique, la valeur moyenne géométrique et la valeur d'écart type. L'analyse de MCSA basée sur l'analyse de composantes principales (ACP) a été utilisée efficacement et plus particulièrement l'erreur de prédiction de carré SPE, ce dernier est évalué en prenant la différence carrée entre les valeurs observées et prédites à partir du modèle de référence de l'état normal prévu. Le SPE dépend de tous les variables à surveiller. Cependant, le SPE est un test global qui combine l'erreur de modélisation présente sur chaque résidu et la comparaison des SPE définit les variables offensantes. Les résultats de simulation avec leurs interprétations décrivent la

présence d'une signature périodique dans la composante actuelle présentée par certains facteurs d'influence importants liés directement à la précision de calcul de la dimension de corrélation sont discutés dans [121]. Dans la recherche d'une technique simple mais efficace, le test de Kolmogorov-Smirnov (KS) a été utilisé pour identifier avec succès la présence la présence de fissures de fatigue sur les pignons droits [122]. Le domaine temporel est un outil statistique adéquat permettant de comparer les fonctions de répartition cumulative empirique de distribution (ECDF) du couplage rigide et du couplage flexible. Ceci modifie grandement les couples dynamiques sur le moteur et donc les courants résultants.




Figure 4.1- Schémas de système expérimental proposés avec deux types d'accouplement : (a) accouplement flexible (b) accouplement rigide. (Photo_Dept-électromécanique d'UBMA).

4.2 Présentation du système expérimental

Les figure 4.2 et 4.3 montrent la configuration expérimentale utilisée pour l'essai d'engrenage pour mesurer les trois courants de phase de stator : I_A , I_B et I_C , où ils ont été enregistrés à partir d'un moteur à induction entraînant d'une boîte de vitesse à 3 étages parallèles à dentures hélicoïdales, dans cinq conditions y compris: la boîte de vitesses dans l'état normale, le test réalisé a été réalisé de la manière suivante : d'abord il a été réalisé par piqûre volontaire de la dent de roue Z_2 , puis on a recouvert la dent de roue concernée Z_2 par du ruban adhésif, deuxièmement, une fois le ruban adhésif enlevé, nous avons procédé à la mesure de la piqûre des deux dents de roue de Z_2 et Z_4 . Enfin, nous avons recouvert les piqûres des deux dents de roue Z_2 et Z_4 et nous avons procédé à mesurer la rupture sur le coin des dents de roue Z_2 et Z_4 . L'instrumentation du système se compose d'un capteur du courant à effet hall (0.01-10A) marque de type Chauvin Arnoux model PAC 12. L'acquisition des signaux pour le diagnostic a été faite par un oscilloscope numérique HAMEG 507 connecté à un capteur de courant qui permet l'acquisition du signal de 8 bits avec une fréquence d'échantillonnage entre 1 kHz et

2,5 MHz. Les courants des stators ont acquis grâce à la carte d'oscilloscope intégré à partir d'un logiciel appelé SP107E. Une liaison élastique est fixée à l'accouplement au moyen d'un disque de matière plastique ayant une épaisseur de 2,5 mm, par conséquent, nous avons enveloppé les boulons de connexion avec une matière plastique, afin d'observer la différence obtenue à l'issue de l'application des fonctions de distribution cumulatives (ECDF) pour différents types de raccords. Le traitement des données est effectué en utilisant le logiciel Matlab pour l'analyse du signal.

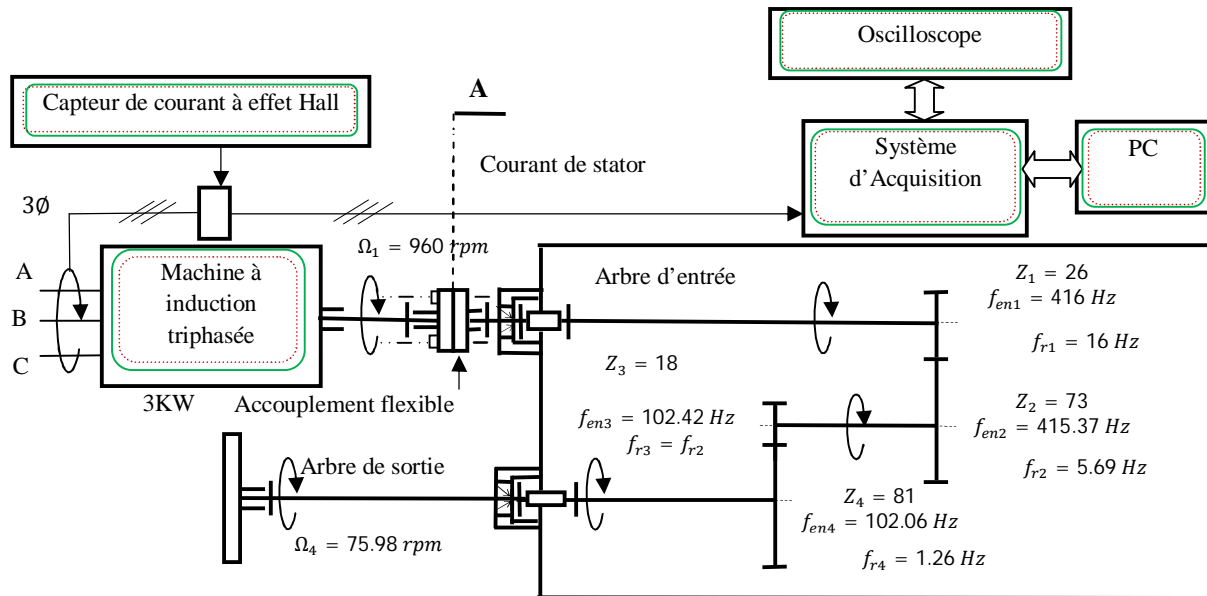


Figure 4.2- diagramme de schéma du dispositif expérimental ($Z_1 = 26$ $Z_2 = 73$ $Z_3 = 18$ $Z_4=81$).




Figure 4.3- différents cas d'essai pour le réducteur de vitesse Actuelle utilisée dans le test : (1) Cassure locale à l'angle d'un engrenage de dent Z_4 . (2) Piqûres de deux dents de la roue Z_4 . (3) Piqûres des deux dents de la roue Z_2 . (4) Zoom sur les piqûres des deux dents de la roue Z_2 .

4.3 La méthodologie et les techniques proposées de diagnostic des défaillances

L'algorithme de diagnostic de défaut proposé dans ce travail suit les étapes suivantes :

- Initialement, les courants des phases des stators sont échantillonnés pour N points où $N = 2046$ est le nombre total d'échantillons dans une fenêtre, compte tenu en particulier du régime permanent et démarré la fenêtre de k où k est généralement un nombre entier compris entre 0 et $N - 1$, dans notre cas nous avons pris $k \in [500 N - 1]$.

- La Norme des vecteurs IA, IB et IC est calculée puis l'approche FFT est utilisée.

- Application de l'algorithme de l'entropie multi-échelle (MSE) ce dernier est basé sur l'application de SampEn pour différentes échelles du même processus au lieu de la mesure de régularité utilisée traditionnellement ApEn statistiques. Les détails sur l'algorithme de SampEn peuvent être trouvés dans de nombreuses littératures [123,124]. SampEn mesure la régularité des données série. Elle fournit une mesure de la vraisemblance que deux séquences de m points de données consécutifs à l'intérieur d'une tolérance donnée r restent similaires lorsqu' un point consécutif est inclus. SampEn augmente lorsque r diminue, parce que le critère pour la séquence correspondante devient plus rigoureux. Par conséquent, la détermination de ces deux paramètres est importante.

Dans l'analyse MSE, une série de temporelle grossière est d'abord construite à partir de la série temporelle d'origine $\{x_1, \dots, x_i, \dots, x_N\}$. On construit des séries chronologiques consécutives grossières $\{y^{(\tau)}\}$ avec le facteur d'échelle $\tau\{\tau = 1, 2, \dots, N\}$ selon l'équation:

$$y_j^{(\tau)} = 1/\tau \sum_{i=(j-1)\tau+1}^{j\tau} x_i \quad (4.1)$$

Où τ représente le facteur d'échelle et $1 \leq j \leq N / \tau$. Pour ajuster les valeurs des paramètres du SampEn, nous avons pris les valeurs de $m = 2$ et $r = 0.15$.

- Essai des valeurs manquantes pour les indicateurs IA, IB et IC .

- Quatre statistiques à travers MSE sont disponible calculés (mean (m_i), Std (s_i), geo mean (gm_i) and max (mx_i)).

- Norme des indicateurs (mean (m_i), Std (s_i), geo mean (gm_i) and max (mx_i)).Sont calculées.

- Utilisant la stratégie de débruitage basée sur la décomposition et la reconstruction optimales des Ondelettes.

- Utilisation de la statistique multivariées : ($SPE_{(approximation)}$ et $T_{(Detail,approximaion)}^2$).

- Modélisation par l'ACP et l'évaluation de l'erreur quadratique de prédiction (SPE) en prenant la différence carrée entre les valeurs observées et les valeurs prédites de l'état normal ou du modèle de référence:

$$SPE = \sum_{i=1}^k (x_{ij} - \bar{x}_{ij})^2 \tag{4.2}$$

Où x_{ij} et \bar{x}_{ij} sont les valeurs mesurées et les valeurs prédites, respectivement par le modèle PCA. Dans un premier temps, un modèle a été développé à partir d'un ensemble de données de conditions normales utilisant k composantes principales et cet ensemble de données a été décomposé comme suit:

$$X = TP^T \tag{4.3}$$

- Utilisation de l'approche de classification (clustering soustractif).

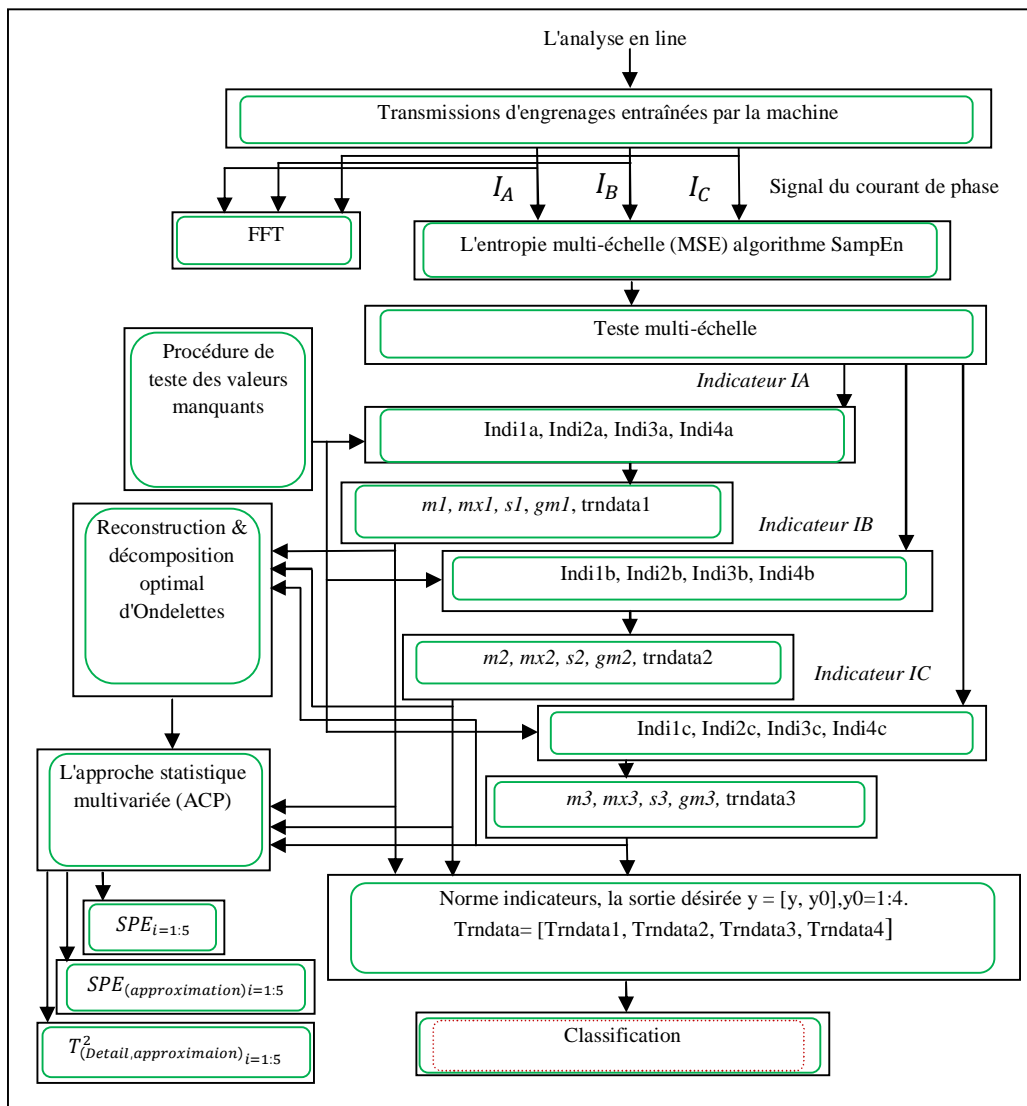


Figure 4.4- Algorithme de détection des défaillances utilisant l'entropie multi-échelle MSE, statistique multivariée et la décomposition d'Ondelettes.

La procédure de diagnostic et détection des défaillances du réducteur de vitesses est donnée par (Figure 4.4), des acquisitions du signal du courant statorique ont été réalisées en régime transitoire et permanent dans les différents modes de fonctionnement qui sont :

1. l'état normal, fonctionnement de réducteur avec une machine saine.
2. les défauts d'engrenages :
 - (piqûre à dent de roue dentée (Z_2)).
 - Piqûre à dent de roue dentée (Z_4).
 - Piqûres des deux dents des engrenages (Z_2 et Z_4).
 - La rupture locale à l'angle des dents des engrenages (Z_2 et Z_4).

est illustrée par l'algorithme de la figure 4.4. Cet algorithme peut être mis en œuvre dans des cartes basées sur le traitement de signal numérique (DSP) qui ont la capacité de traitement et de mémoire pour exécuter l'approche proposée. Les valeurs des paramètres utilisés dans cet algorithme peuvent être optimisées pour tenir compte des caractéristiques des signaux présents dans l'environnement industriel et être mises œuvre dans un produit commercial.

Les valeurs de caractéristiques réduites constituent la base de données du système expert de diagnostic de défaut proposé. La base de données globale est divisée en un ensemble de données de 250 échantillons et la base de données locale est divisée en un ensemble de données d'apprentissage 50 échantillons et un ensemble de données d'essai global 135 échantillons et ensemble de données d'essai local 27 échantillons. Le jeu de données est utilisé pour former le modèle de classificateur, afin d'aborder les sorties attendues.

4.4 Influence des défaillances dans les différents cas d'études sur MCSA

4.4.1 Influence des défaillances sur les grandeurs triphasées

Les évolutions des signaux des courants statoriques sont déduites à partir de la figure 4.3, on peut remarquer que la présence des défauts est à peine visible sur les signaux de courant de phase de stator (figure 4.5.a et figure 4.5.b). Mais si les composants 50 Hz et 150 Hz sont entaillés (directement dans le spectre FFT de manière à obtenir un filtre idéal à changement de phase nul), les signaux de temps résiduels sont considérés comme sensibles aux défauts de transmission (figure 4.5.c).

Cette observation souligne l'intérêt de l'inspection des signaux des courants statoriques par des méthodes plus efficaces de traitement de signal comme (le spectre de courant du stator, l'entropie multi-échelle (MSE), l'analyse statistique multivariée et la décomposition d'Ondelettes) afin de dégager l'effet du défaut d'engrenage sur la signature des courants du machine à induction.

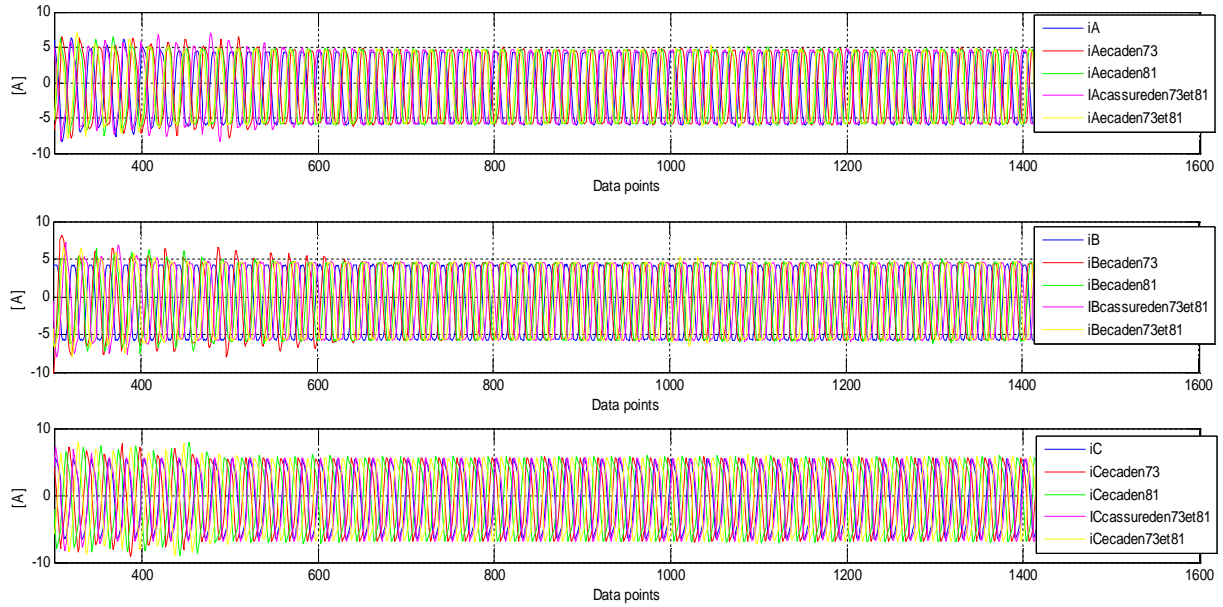


Figure 4.5.a- Evolutions des différents signaux de courant des phases IA,IB et IC pour le réducteur sans défaillance (état sain) et les défaillances affectant les différents cas (Fig 4.3).

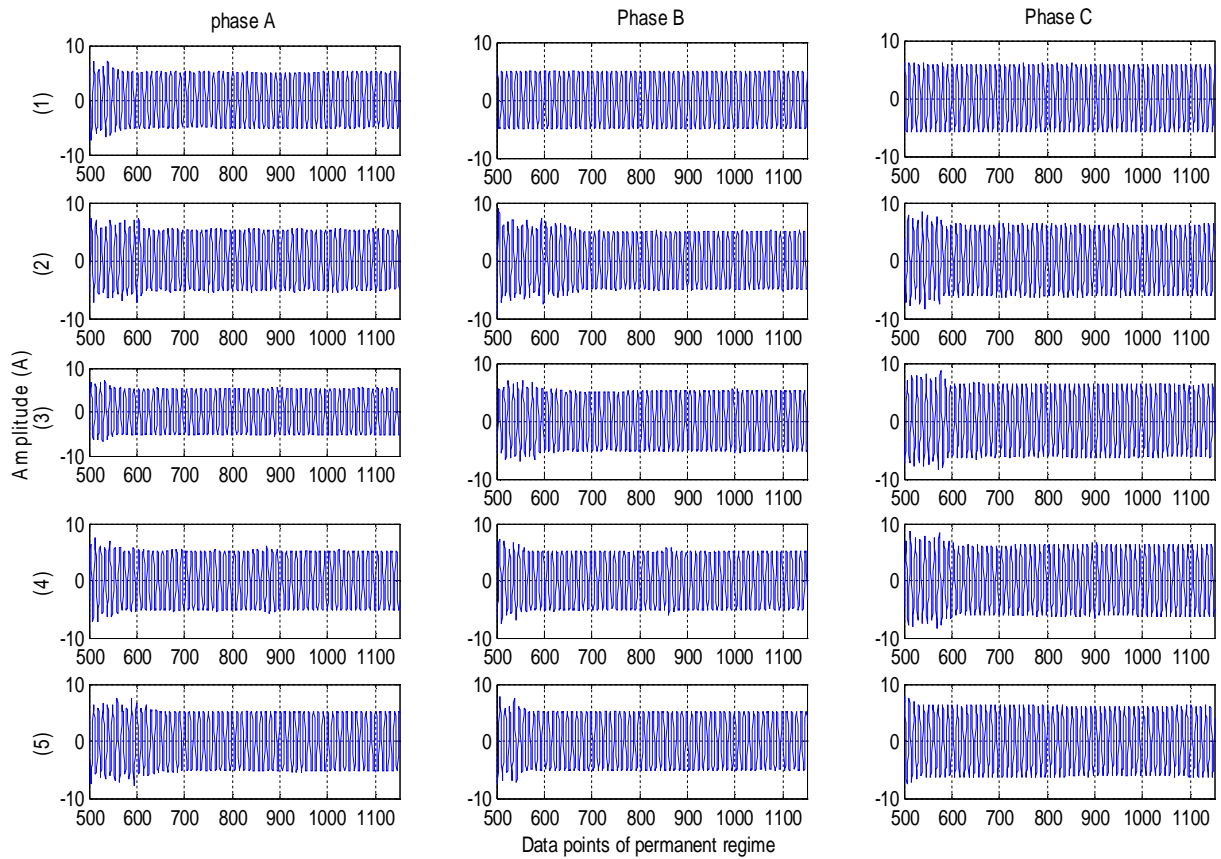


Figure 4.5.b- Les signaux de courant ont été enregistrés à partir d'un réducteur de vitesse dans les cinq conditions, y compris: l'état normale, les défauts d'engrenages (piqûre à dent de roue dentée (Z_2), piquûre à dent de roue dentée (Z_4), piquûres des deux dents des engrenages (Z_2 et Z_4) et la rupture locale à l'angle des dents des engrenages (Z_2 et Z_4).




Figure 4.5.c- Evolution des signaux de temps résiduels de la figure 4.5.b.

4.4.2 Influence des défaillances sur l'analyse en composantes principales

Figure 4.6 montre l'évolution des composantes principales t_1, \dots, t_5 , on note que l'impact du défaut sur les composantes $t_1 \dots t_4$ n'apparaît pas aussi évident alors que le t_5 dernier composant efface l'effet de la présence de rupture à l'angle des dents et de la solution par le dernier t_5 composant présenté dans la Figure 4.6, on peut observer une récurrence périodique des perturbations dues au défaut et est clairement visible avec la période de tm . $Z_{2,4}$, sachant que $Z_{2,4}$ est le nombre de dents du pignon et tm est la période d'engrènement. Ces perturbations sont observées à la suite des techniques d'analyses de courant cités par [105,115 et 117] de la défaillance de l'engrenage et répétées régulièrement lorsque la dent défectueuse en prise.

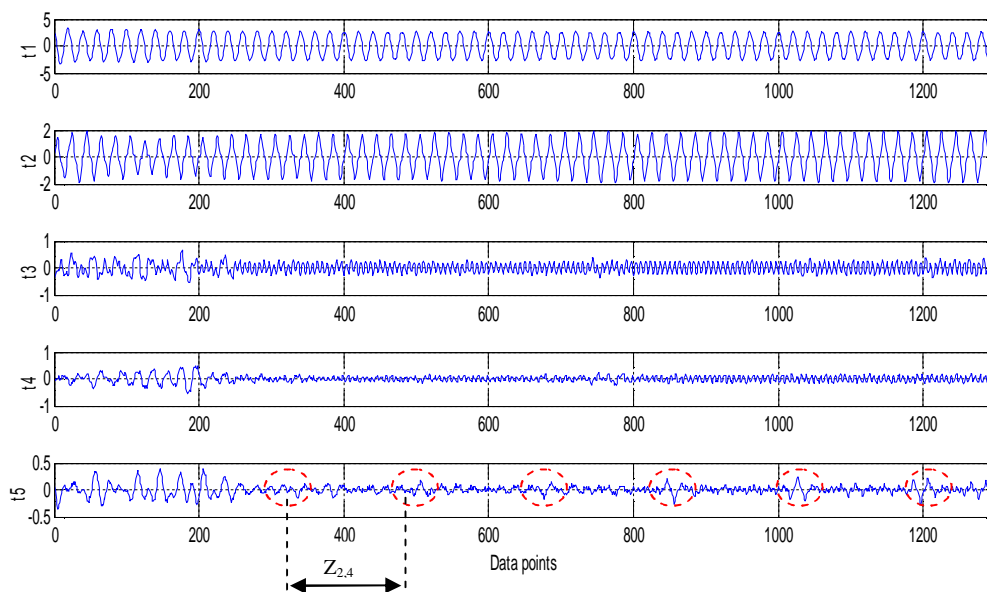


Figure 4.6- L'évolution de l'analyse en composantes principales du courant de phase IA.

4.5 Détection des défaillances d'engrenage basée sur l'analyse spectrale

L'objectif de cette partie est d'étudier l'influence des défauts d'engrenage sur les signaux des courants statoriques en utilisant l'analyse spectrale.

Réellement, les défauts d'engrenage conduisent à la variation de la vitesse angulaire instantanée du rotor d'une part, et d'autre part à la modification de l'épaisseur de l'entrefer de la machine à induction. La figure 4.7 décrit le spectre de phase de courant IA, IB et IC dans le cas sain et en présence d'une dégradation de la boîte de vitesses dans la largeur de bande de fréquence [0 Hz, 500 Hz] pour une machine à induction triphasée de 3 KW connectée à une boîte de vitesses avec ($Z_1 = 26$ et $Z_2 = 73$ et $Z_3 = 18$ et $Z_4=81$) respectivement, le nombre de dents d'entrée et de sortie) et ($f_{r1} = 16$ Hz et $f_{r2} = 5.69$ Hz et $f_{r3} = f_{r2}$ et $f_{r4} = 1.26$ Hz) sont respectivement les fréquences de rotation d'entrée et de sortie. La figure 4.8 (1) présente les vecteurs de Norme du spectre de phase de courant IA, IB et IC dans le cas sain, la fréquence de la roue dentée engrenant et ses harmoniques sont les composantes de fréquences dominantes dans le spectre du courant du stator. La figure 4.8 (2) représente le spectre des vecteurs de Norme de courant de stator lorsque le pignon Z_2 présente un défaut de piqûre sur la dent. Sur l'émergence actuelle d'un rayon, le spectre remarquable est détecté à des fréquences $[50 \pm f_{r1}]$, $[50 \pm f_{r2}]$ avec $f_{r1} = 16$ Hz et $f_{r2} = 5,69$ Hz. L'apparition des bandes latérales peut être attribuée à l'interaction entre la fréquence à engrenage et les fréquences naturelles. Il y a également quelques lignes latérales en forme de peigne de f_{r2} Hz à faible amplitude qui peuvent être observées autour de la fréquence naturelle de la conduite d'entraînement (ce qui correspond à l'accouplement du moteur de la boîte de vitesses). La figure 4.8 (3) représente le spectre des vecteurs de norme de courant de stator lorsque le pignon Z_4 présente un défaut de piqûre d'une dent. Sur l'émergence actuelle d'un rayon le spectre remarquable est détecté à des fréquences $[50 \pm f_{r3}]$, $[50 \pm f_{r4}]$ avec $f_{r3} = 5,69$ Hz et $f_{r4} = 1,26$ Hz et aussi un côté peigne lignes de $n f_{r4}$ avec une faible amplitude, peuvent être observées. La figure 4.8 (4) représente le spectre de vecteurs Norme du courant du stator, en présence de piqûres sur les deux dents des roues dentées Z_2 et Z_4 . Les caractéristiques de fréquence des défauts de circulation $[50 \pm 16$ Hz], $[50 \pm 5.69$ Hz], $[50 \pm 1.26$ Hz], $[50 \pm n$ (Hz) 5,69] et $[50 \pm n$ (Hz) 1,26]. La figure 4.8 (5) et la Figure 4.8 (6) représente le spectre des vecteurs de Norme du courant du stator en présence de coupure locale à l'angle des dents des engrenages Z_2 et Z_4 . Une émergence de fréquences de la série de la ligne $[50 \pm n$ (1.26) Hz] avec une augmentation de leur nombre signifiant le degré de dégradation de la surface de ces dents de contact.

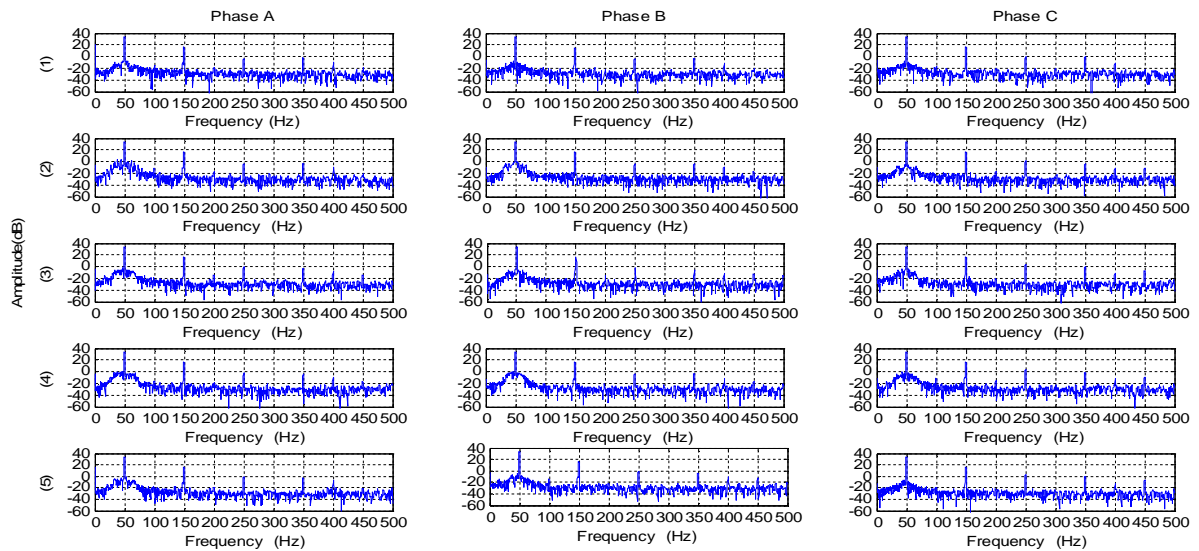


Figure 4.7- Evolutions des différents spectres de courant Stator pour l'état sain et les défaillances affectant les différents cas (Figure 4.3).

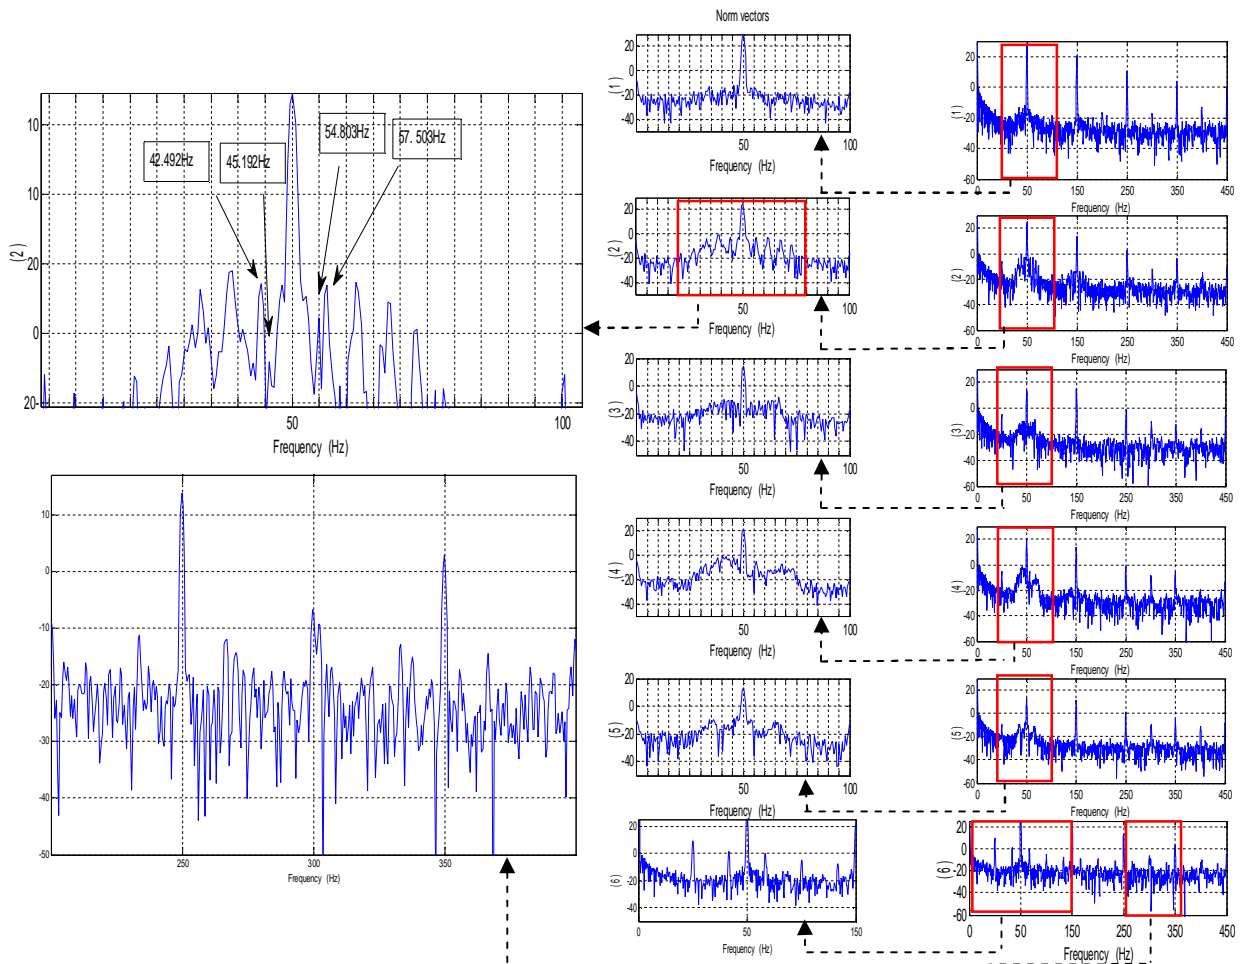


Figure 4.8- Evolutions des différents Spectres des vecteurs Norme de courant Statorique pour : (1) l'état sain et (1-5) les défaillances affectant les différents cas (Figure 4.3) (6) la rupture locale sur le coin des dents d'engrenages ($Z_2 + Z_4$) avec raccord flexible et 90% de la charge nominale.

En comparant les spectres des courants en présence des différents défauts figures 4.7 (2-5) et figures 4.8 (2-6) par rapport au spectre du courant statorique du notre système électro-énergétique sain figure 4.7 (1) et figure 4.8 (1) ; des pics additionnels liés à la fréquence de rotation du pignon f_r modulée par la fréquence d'alimentation du stator f_s peuvent être repérés. Les vues zoomées de la figure 4.8 révèlent des pics à des fréquences et des amplitudes différentes et distinctives montrant ainsi que les fréquences spécifiques à chaque type de défaut peuvent être identifiées.

Les fréquences identifiées précédemment peuvent être exprimées sous formes générales similaires aux expressions suivantes [125]:

$$\begin{aligned}
 f_{Gr(i)(i=1:2)} &= \left| f_s \pm m_{(\alpha=1,2,3\dots)} f_{r(i)(i=1:2)} \right| \\
 f_{Gr(j)(j=3:4)} &= \left| f_s \pm n_{(\alpha=1,2,3\dots)} f_{r(j)(j=3:4)} \right| \\
 f_{Gr(j)(j=3:4)r(i)(i=1:2)} &= \left| f_s \pm n_{(\alpha=1,2,3\dots)} f_{r(j)(j=3:4)} f_s \pm m_{(\alpha=1,2,3\dots)} f_{r(i)(i=1:2)} \right| \\
 f_{Gen} &= \left| f_s \pm q_{(\alpha=1,2,3\dots)} f_{en(i)(i=1:n(n=1:4))} \right| \\
 f_{Gr(i)(i=1:2)en} &= \left| f_s \pm m_{(\alpha=1,2,3\dots)} f_{r(i)(i=1:2)} \pm q_{(\alpha=1,2,3\dots)} f_{en(i)(i=1:n(n=1:4))} \right| \\
 f_{Gr(j)(j=3:4)en} &= \left| f_s \pm n_{(\alpha=1,2,3\dots)} f_{r(j)(j=3:4)} \pm q_{(\alpha=1,2,3\dots)} f_{en(i)(i=1:n(n=1:4))} \right| \\
 f_{Gr(j)(j=3:4)r(i)(i=1:2)en} &= \\
 &= \left| f_s \pm m_{(\alpha=1,2,3\dots)} f_{r(i)(i=1:2)} \pm n_{(\alpha=1,2,3\dots)} f_{r(j)(j=3:4)} \pm q_{(\alpha=1,2,3\dots)} f_{en(i)(i=1:n(n=1:4))} \right| \quad (4.4)
 \end{aligned}$$

La fréquence d'engrènement de deux engrenages n et $m \in [1 \ 2]$ est calculée par la formule suivante :

$$f_{en(i)(i=1:n(n=1:4))} = Z_{(i)(i=1:n-1)} \cdot f_{r(i)(i=1:n)} = Z_{(i+1)(i=1:n-1)} \cdot f_{r(i+1)(i=1:n-1)} \quad (4.5)$$

Avec

$$\omega_{r(i=1:4)} = 2\pi f_{r(i=1:4)} \quad (4.6)$$

$$\omega_{en} = 2\pi f_{en} \quad (4.7)$$

Soient,

$\omega_{r(i=1:4)}$: La fréquence angulaire du rotor (rad).

$f_{r(i)(i=1:4)}$: La fréquence de rotation (Hz).

$Z_{(i)(i=1:4)}$: Le nombre de dents.

$f_{en(i)(i=1:4)}$: Les fréquences d'engrènement (Hz).

4.6 Effet mécanique de la boîte de vitesses dans MCSA

Les défauts localisés par les dents, contrairement aux défauts répartis dans les dentures, produisent dans les engrenages des chocs mécaniques importants à la périodicité de la fréquence de rotation correspondant à l'emplacement du défaut dans le signal, qui est principalement dû à la transmission du couple mécanique. Sur la base d'études [125], le couple de charge observé par une machine à induction couplée à un engrenage sain $T_{LH}(t)$ se compose d'une valeur moyenne et d'une partie variable dans le temps, qui peut être écrite comme suit :

$$T_{LH}(t) = T_{const} + T_{osc}(t) \quad (4.8)$$

$$\begin{aligned} T_{osc}(t) &= \sum_h T_{r1h} \cos(h\omega_{r1}t + \eta_{r1h}) + \sum_i T_{r2i} \cos(i\omega_{r2}t + \eta_{r2i}) + \sum_j T_{r3j} \cos(j\omega_{r3}t + \\ &\quad \eta_{r3kj}) + \sum_k T_{r4k} \cos(k\omega_{r4}t + \eta_{r4k}) + \sum_l^4 T_{enl} \cos(l\omega_{en}t + \eta_{enl}) \\ &= \sum_{i(i=1:4)} T_{r(i=1:4)} \cos(i\omega_{r(i=1:4)}t + \eta_{r(i=1:4)}) + \sum_l^4 T_{enl} \cos(l\omega_{en}t + \eta_{enl}) \end{aligned} \quad (4.9)$$

Où T_{const} est une composante constante moyenne de couple, et T_{osc} est l'oscillation du couple de charge liée à la fois aux pignons à engrenages et aux rotations de la roue plus les composantes d'engrènement.

Avec:

T_{enl} : L'oscillation d'amplitude de couple liée aux fréquences d'engrènements.

η_{r1h} , η_{r2i} , η_{r3kj} , η_{r4k} et η_{enl} : entrées, sorties des oscillations des rotations reliés aux des angles des phases.

L'impact mécanique du défaut génère une composante supplémentaire périodique, cette dernière peut être représentée par la série de Fourier en plus de l'état sain. Par conséquent, le couple en état défectueux $T_{LF}(t)$ peut être formulé comme suit :

$$T_{LF}(t) = T_{LH}(t) + T_{fp}(t) \quad (4.10)$$

Avec

$$T_{fp}(t) = \sum_{k=1}^{+\infty} T_k \cos(k\omega_{fp}t + \varphi_k), \quad \omega_{fp} = 2\pi f_{fp} \quad (4.11)$$

Où f_{fp} : La fréquence fondamentale de défaut (en relation avec le pignon ou les fréquences de rotation des roues).

Avec T_k , et φ_k peut être obtenu à partir du profil de défaut de la série coefficients de Fourier. Si l'on considère la dynamique mécanique d'une machine à induction en utilisant (4.9) et en sachant que dans le régime permanent de couple électromagnétique moyen est égal à T_{const} , la vitesse du rotor est obtenue comme suit si le coefficient de frottement est négligé [126] :

$$\omega_r(t) = -\frac{1}{J} \int_{t_0}^t T_{osc}(\tau) d\tau + \omega_{r0} \quad (4.12)$$

Où ω_{r0} est la valeur moyenne.

J : Inertie équivalente au niveau du rotor.

La position mécanique du rotor $\theta_r(t)$ Peut être calculée comme suit:

$$\theta_r(t) = \int_{t_0}^t \omega_r(\tau) d\tau = \frac{1}{p} \chi(t) + \omega_{r0}t + \theta_{r0} \quad (4.13)$$

Avec

$$\begin{aligned} \chi(t) &= \sum_h \beta_{r1h} \cos(h\omega_{r1}t + \eta_{r1h}) + \sum_i \beta_{r2i} \cos(i\omega_{r2}t + \eta_{r2i}) + \sum_j \beta_{r3j} \cos(j\omega_{r3}t + \eta_{r3kj}) \\ &+ \sum_k \beta_{r4k} \cos(k\omega_{r4}t + \eta_{r4k}) + \sum_l^4 \beta_{enl} \cos(l\omega_{en}t + \eta_{enl}) \\ &= \sum_{i(i=1:4)} \beta_{r(i=1:4)} \cos(i\omega_{r(i=1:4)}t + \eta_{r(i=1:4)}) + \sum_l^4 \beta_{enl} \cos(l\omega_{en}t + \eta_{enl}) \end{aligned} \quad (4.14)$$

$$\begin{aligned} \beta_{r1h} &= p \frac{T_{r1h}}{Jh(\omega_{r1})^2} & \beta_{r2i} &= p \frac{T_{r2i}}{Ji(\omega_{r2})^2} & \beta_{r3j} &= p \frac{T_{r3j}}{Jj(\omega_{r3})^2} & \beta_{r4k} &= p \frac{T_{r4k}}{Jk(\omega_{r4})^2} \\ \beta_{enl} &= p \frac{T_{enl}}{Jl(\omega_{en})^2} \end{aligned} \quad (4.15)$$

$$\omega_{r0} = \omega_s \frac{(1-s)}{p} \quad (4.16)$$

Avec

p : Nombre de paires de pôles.

s : Le glissement du rotor.

ω_s : La fréquence angulaire fondamentale du stator.

4.7 L'équation mathématique du MCSA avec la prise en charge de réducteur 3 étages

Le flux $\theta(t)$ peut être obtenu par l'intégration de la densité de flux tout en respectant θ^s avec

$$\theta^s = \theta^r + \theta_r(t)$$

$$\left(\theta^s = \theta^r + \frac{1}{p} \chi(t) + \frac{1-s}{p} \omega_s t + \theta_{r0}\right) \quad (4.17)$$

θ^s : Angle de circonférence dans le cadre de référence fixe.

θ^r : Angle de circonférence dans le cadre de référence du rotor.




Figure 4.9- schéma de référence Statorique et rotorique.

Pour une bobine de stator arbitraire. Le flux peut être exprimé comme suit :

$$\Phi(t) = \Phi_s \cos(\omega_s t + \eta_s) + \Phi_r \cos(\omega_s t + \chi(t) + \eta_r) \quad (4.18)$$

Et la tension induite dans les bobines de stator qui décrit la relation entre le flux et le courant de stator peut être écrite comme:

$$\begin{aligned} V(t) &= \frac{d}{dt} \Phi(t) + R_s I(t) \\ &= -\Phi_s \omega_s \sin(\omega_s t + \eta_s) - \Phi_r \omega_s \sin(\omega_s t + \chi(t) + \eta_r) + \Phi_r \sin(\omega_s t + \chi(t) + \eta_r) \times \\ &[\sum_h \beta_{r1h} h \omega_{r1} \sin(h \omega_{r1} t + \eta_{r1h}) + \\ &\sum_i \beta_{r2i} i \omega_{r2} \cos(i \omega_{r2} t + \eta_{r2i}) + \sum_j \beta_{r3j} j \omega_{r3} \cos(j \omega_{r3} t + \eta_{r3kj}) + \\ &\sum_k \beta_{r4k} k \omega_{r4} \cos(k \omega_{r4} t + \eta_{r4k}) + \sum_l^4 \beta_{enl} l \omega_{en} \cos(l \omega_{en} t + \eta_{enl})] \end{aligned} \quad (4.19)$$

$$\begin{aligned} V(t) &= -\Phi_s \omega_s \sin(\omega_s t + \eta_s) - \Phi_r \omega_s \sin(\omega_s t + \chi(t) + \eta_r) - \frac{\Phi_r}{2} [\sum_h \beta_{r1h} h \omega_{r1} \{ \cos[(\omega_s + \\ &h \omega_{r1})t + \chi(t) + \eta_{r1h} + \eta_r] - \cos[(\omega_s - h \omega_{r1})t + \chi(t) - \eta_{r1h} + \eta_r] \} + \\ &\sum_i \beta_{r2i} i \omega_{r2} \{ \cos[(\omega_s + i \omega_{r2})t + \chi(t) + \eta_{r2i} + \eta_r] - \cos[(\omega_s - i \omega_{r2})t + \chi(t) - \eta_{r2i} + \\ &\eta_r] \} + \sum_j \beta_{r3j} j \omega_{r3} \{ \cos[(\omega_s + j \omega_{r3})t + \chi(t) + \eta_{r3j} + \eta_r] - \cos[(\omega_s - j \omega_{r3})t + \chi(t) - \\ &\eta_{r3j} + \eta_r] \} + \sum_k \beta_{r4k} k \omega_{r4} \{ \cos[(\omega_s + k \omega_{r4})t + \chi(t) + \eta_{r4k} + \eta_r] - \cos[(\omega_s - k \omega_{r4})t + \\ &\chi(t) - \eta_{r4k} + \eta_r] \} + \sum_l \beta_{enl} l \omega_{en} \{ \cos[(\omega_s + l \omega_{en})t + \chi(t) + \eta_{enl} + \eta_r] - \cos[(\omega_s - \\ &l \omega_{en})t + \chi(t) - \eta_{enl} + \eta_r] \}] \end{aligned} \quad (4.20)$$

Le courant de stator peut être exprimé en fonction d'un terme de stator non modulé I_s , les autres termes dépendant de la modulation de phase donnée par $\chi(t)$ dans (4.14), avec

$$\begin{aligned}
 \chi'(t) &= \sum_h \beta'_{r1h} \cos(h\omega_{r1}t + \eta'''_{r1h}) \\
 &\quad + \sum_i \beta'_{r2i} \cos(i\omega_{r2}t + \eta'''_{r2i}) + \sum_j \beta'_{r3j} \cos(j\omega_{r3}t + \eta'''_{r3kj}) \\
 &\quad + \sum_k \beta'_{r4k} \cos(k\omega_{r4}t + \eta'''_{r4k}) + \sum_l^4 \beta'_{enl} \cos(l\omega_{en}t + \eta'''_{enl}) \\
 &= \sum_{i(i=1:4)} \beta'_{r(i=1:4)} \cos(i\omega_{r(i=1:4)}t + \eta'''_{r(i=1:4)}) + \sum_l^4 \beta'_{enl} \cos(l\omega_{en}t + \eta'''_{enl}) \quad (4.21)
 \end{aligned}$$

Avec :

$$\beta'_{r1h} \propto \beta_{r1h} \quad \beta'_{r2i} \propto \beta_{r2i} \quad \beta'_{r3j} \propto \beta_{r3j} \quad \beta'_{r4k} \propto \beta_{r4k} \quad \beta'_{enl} \propto \beta_{enl} \quad (4.22)$$

$$\begin{aligned}
 I(t) &\approx I_s \sin(\omega_s t + \eta_s) + I_r \sin(\omega_s t + \chi'(t) + \eta'_r) + \frac{\emptyset_r}{2} [\sum_h \beta_{r1h} h\omega_{r1} \{ \Gamma_{r1h} \cos[(\omega_s + h\omega_{r1})t + \chi'(t) + \eta'_{r1h}] - \Gamma'_{r1h} \cos[(\omega_s - h\omega_{r1})t + \chi'(t) + \eta''_{r1h}] \} + \\
 &\quad \sum_i \beta_{r2i} i\omega_{r2} \{ \Gamma_{r2i} \cos[(\omega_s + i\omega_{r2})t + \chi'(t) + \eta'_{r2i}] - \Gamma'_{r2i} \cos[(\omega_s - i\omega_{r2})t + \chi'(t) + \eta''_{r2i}] \} + \sum_j \beta_{r3j} j\omega_{r3} \{ \Gamma_{r3j} \cos[(\omega_s + j\omega_{r3})t + \chi'(t) + \eta'_{r3j}] - \Gamma'_{r3j} \cos[(\omega_s - j\omega_{r3})t + \chi'(t) + \eta''_{r3j}] \} + \\
 &\quad \sum_k \beta_{r4k} k\omega_{r4} \{ \Gamma_{r4k} \cos[(\omega_s + k\omega_{r4})t + \chi'(t) + \eta'_{r4k}] - \Gamma'_{r4k} \cos[(\omega_s - k\omega_{r4})t + \chi'(t) + \eta''_{r4k}] \} + \sum_l \beta_{enl} l\omega_{en} \{ \Gamma_{enl} \cos[(\omega_s + l\omega_{en})t + \chi'(t) + \eta'_{enl}] - \Gamma'_{enl} \cos[(\omega_s - l\omega_{en})t + \chi'(t) + \eta''_{enl}] \} \quad (4.23)
 \end{aligned}$$

$$I(t) \approx i_{st}(t) + i_{rt}(t) \quad (4.24)$$

Avec

$$i_{st}(t) = I_s \sin(\omega_s t + \eta_s) \quad (4.25)$$

$$\begin{aligned}
 i_{rt}(t) &\approx I_r \sin(\omega_s t + \chi'(t) + \eta'_r) + \frac{\emptyset_r}{2} [\sum_h \beta_{r1h} h\omega_{r1} \{ \Gamma_{r1h} \cos[(\omega_s + h\omega_{r1})t + \chi'(t) + \eta'_{r1h}] - \Gamma'_{r1h} \cos[(\omega_s - h\omega_{r1})t + \chi'(t) + \eta''_{r1h}] \} + \\
 &\quad \sum_i \beta_{r2i} i\omega_{r2} \{ \Gamma_{r2i} \cos[(\omega_s + i\omega_{r2})t + \chi'(t) + \eta'_{r2i}] - \Gamma'_{r2i} \cos[(\omega_s - i\omega_{r2})t + \chi'(t) + \eta''_{r2i}] \} + \sum_j \beta_{r3j} j\omega_{r3} \{ \Gamma_{r3j} \cos[(\omega_s + j\omega_{r3})t + \chi'(t) + \eta'_{r3j}] - \Gamma'_{r3j} \cos[(\omega_s - j\omega_{r3})t + \chi'(t) + \eta''_{r3j}] \} + \\
 &\quad \sum_k \beta_{r4k} k\omega_{r4} \{ \Gamma_{r4k} \cos[(\omega_s + k\omega_{r4})t + \chi'(t) + \eta'_{r4k}] - \Gamma'_{r4k} \cos[(\omega_s - k\omega_{r4})t + \chi'(t) + \eta''_{r4k}] \} + \sum_l \beta_{enl} l\omega_{en} \{ \Gamma_{enl} \cos[(\omega_s + l\omega_{en})t + \chi'(t) + \eta'_{enl}] - \Gamma'_{enl} \cos[(\omega_s - l\omega_{en})t + \chi'(t) + \eta''_{enl}] \} \quad (4.26)
 \end{aligned}$$

$\Gamma_{r1h}, \Gamma'_{r1h}, \Gamma_{r2i}, \Gamma'_{r2i}, \Gamma_{r3j}, \Gamma'_{r3j}, \Gamma_{r4k}, \Gamma'_{r4k}, \Gamma_{enl}$ et Γ'_{enl} : les admittances de la machine à induction vues par la tension d'induction du rotor et leurs fréquences angulaires respectives.

L'équation (4.23) peut être représentée par l'équation (4.24) qui montre qu'à l'exception du premier terme $i_{st}(t)$, et l'exception du second terme $i_{rt}(t)$ qui contient la modulation d'angle $\chi'(t)$ qui représente l'influence de la boîte de vitesses sur le courant du stator. Cette influence est constituée d'une modulation de phase à plusieurs composants liée aux fréquences caractéristiques $f_{r(i)} (i=1:4)$ et $f_{en(i)} (i=1:4)$.

Les fréquences engrènements liées aux $(f_{Gen(i)} (i=1:4), f_{ren(i)} (i=1:4)$ et $f_{Grhri(h,i)} (h,i=1:2) en, f_{Grjrk(jk)} (j,k=1:2) en$) sont difficiles à trouver selon [125].

4.8 Application de la technique d'entropie multi-échelle MSE au diagnostic

Après avoir validé la procédure précédente pour diagnostiquer les défaillances d'engrenages de la boîte à vitesses en utilisant l'analyse spectrale du courant statorique de la machine à induction, nous avons utilisé une autre procédure de diagnostic des défaillances basée sur des combinaison entre différentes approches de diagnostic de défaillances : entropie multi-échelle MSE, l'analyse statistique multi variée et l'analyse en ondelettes DWT, cette dernière est utilisée d'une part, pour filtrer le signal et d'une autre, part pour fournir des informations utiles sur n'importe quel signal dans le domaine de temps pour des bandes de fréquence de court terme. L'analyse du signal est l'une des méthodes les plus importantes utilisées pour la surveillance et le diagnostic des défaillances, dont le but est de trouver une simple et efficace transformée des signaux originaux. Par conséquent, l'information importante contenue dans les signaux peut être extraite. L'utilisation de la technique d'entropie multi-échelle pour la surveillance et le diagnostic des défaillances des réducteurs de vitesse est un avantage car cette technique permet d'améliorer MCSA et prendre en compte non seulement la non-linéarité dynamique, mais aussi des effets d'interaction et de couplage entre les composantes mécaniques [22].

Compte tenu d'une série chronologique de N points, $\{I(1), \dots, I(i), \dots, I(N)\}$, SampEn Peut être défini comme suit [25]:

- Former m longueur vecteurs $I'_m(i)$

$$I'_m(i) = \{I(i), I(i + 1), \dots, I(i + m - 1)\}$$

$$1 \leq i \leq N - m + 1 \quad (4.27)$$

- La distance entre deux vecteurs de ce type est définie comme suit:

$$d[I'_m(i), I'_m(j)] = \max_{k \in [1, m-1]} (|I(i + k) - I(j + k)|) \quad (4.28)$$

- Pour chaque $I'_m(i)$ Et la tolérance fixe r , laisser A_i le nombre de vecteurs qui satisfont $d[I'_m(i), I'_m(j)] \leq r$, puis on désigne $B_i^m(r)$ comme suit:

$$B_i^m(r) = \frac{A_i}{N-m+1} \quad 1 \leq i \leq N - m \quad (4.29)$$

- La moyenne des $B_i^m(r)$ Est désigné comme:

$$B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r) \quad (4.30)$$

- En augmentant la dimension de $m + 1$ Et répéter les étapes précédentes pour trouver $B^{m+1}(r)$, le SampEn est défini comme suit :

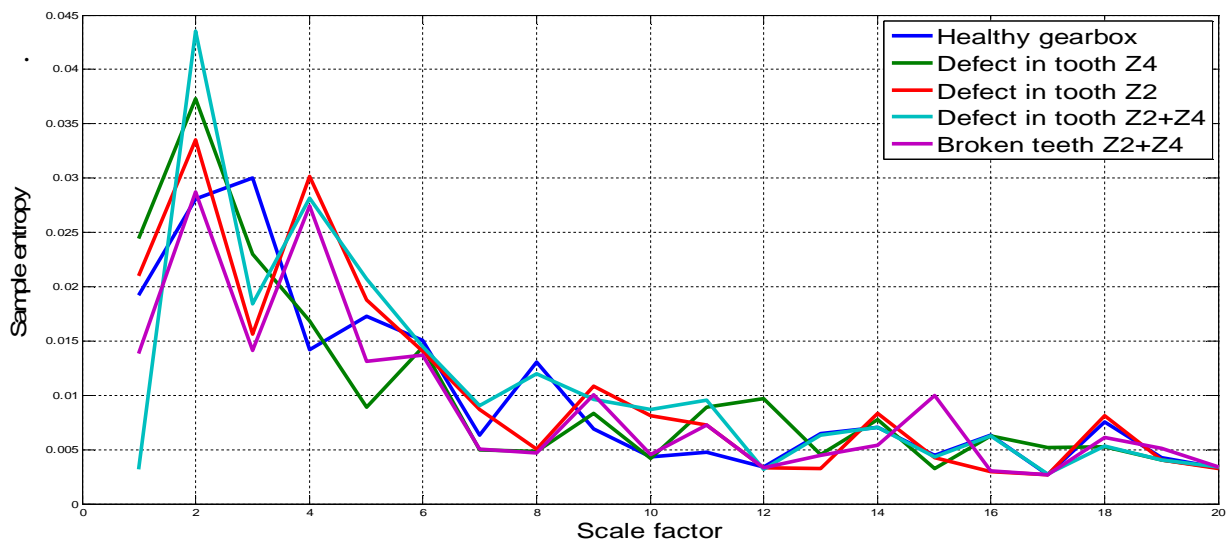
$$SampEn(m, r) = \sum_{N \rightarrow \infty} -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (4.31)$$

Pour un nombre fini de points de données N :

$$SampEn(m, r, N) = -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (4.32)$$

La MSE à travers 20 échelles du signal de courant de phase du stator correspondant IA pour les cas simulés sains et défectueux sont illustrés sur la Figure 4.10, on voit clairement que la MSE de la boîte de vitesses dans des conditions différentes n'a pas les mêmes valeurs d'entropie sur la plupart des échelles, MSE du facteur sept échelles sont significativement importantes et traitent la composante principale de l'énergie totale du signal.

Par conséquent, le facteur de six échelles est raisonnablement choisi pour reconstruire le signal propre. Nous pouvons voir que la SampEn entre sept échelles et vingt échelles de courant de stator correspondant IA oscille autour des différentes valeurs. Afin de réduire le nombre d'entrées à l'approche de classification des défauts, quatre statistiques à travers MSE des courants des phases des stators IA, IB et IC sont utilisés qui sont : la valeur maximale (mx_i), la valeur moyenne arithmétique (m_i), la valeur moyenne géométrique (gm_i) et la valeur de l'écart type (s_i). (Figures 4.12-4.15).



4.10- MSE au cours de 20 échelles du signal de courant de stator correspondant est représenté en figure 4.5-b.




Figure 4.11- Cinq statistiques au cours de MSE du signal de courant de phase est représentées sur la figure 4.10.




Figure 4.12- Quatre statistiques au cours de MSE du signal de courant de phase IA.




Figure 4.13- Quatre statistiques au cours de MSE de la phase de signal de courant IB.

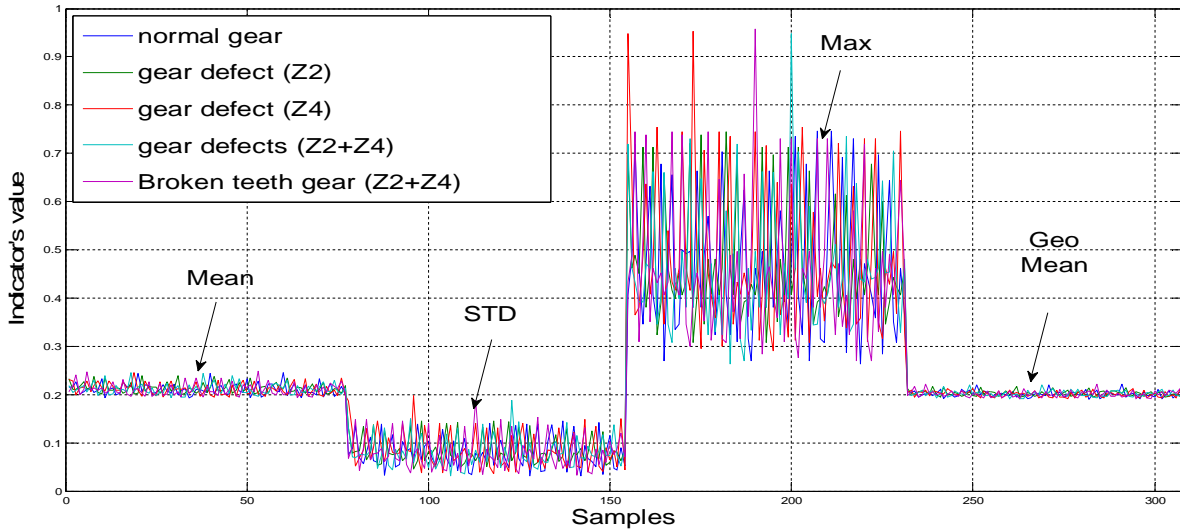


Figure 4.14- Quatre statistiques au cours MSE de la phase de signal de courant IC.

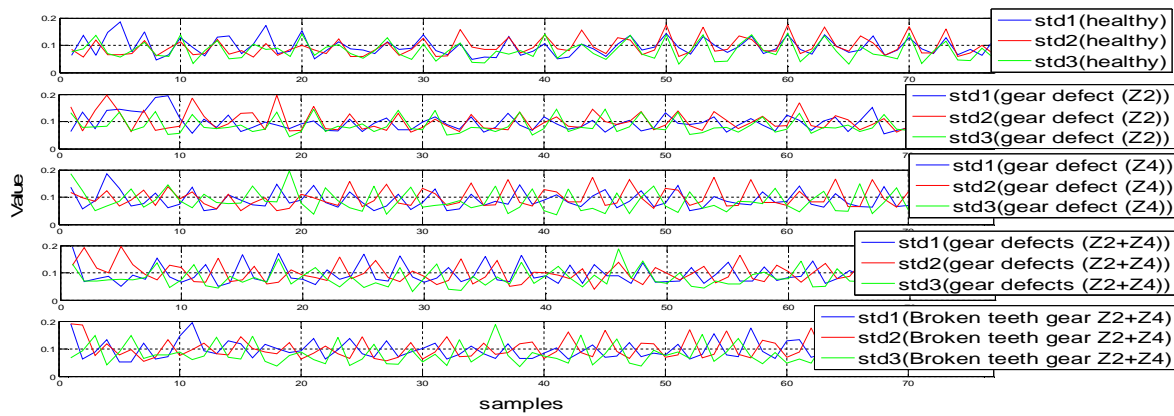


Figure 4.15- STD-au cours de MSE du courant de phase (IA, IB et IC) enregistré à partir d'un réducteur de vitesse dans les cinq conditions.

Afin de valider la classification approcher ces quatre caractéristiques sont ensuite présentées pour une approche de classification des défauts et des statistiques multivariées approche. Nous avons utilisé le MCSA en tant que signaux originaux pour les procédures de formation et d'essai.

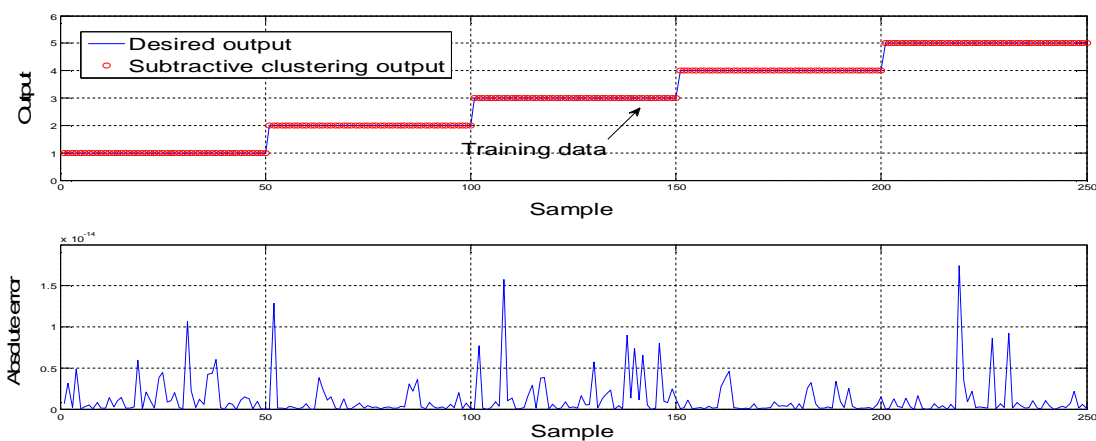


Figure 4.16- L'exécution des données d'apprentissage par rapport aux données de contrôle.

Dans la procédure de formation, les caractéristiques extraites sont utilisées pour adapter le réseau de formation pour chaque état du système moteur-réducteur, la performance des clusters soustractifs au cours de la formation efficace réalisée en utilisant l'approche proposée.




Figure 4.17- Comparaison des résultats.

4.9 Application de la technique des ondelettes au diagnostic

Pour améliorer la qualité de la détection et réduire le taux de fausses alarmes, nous utilisons la transformée d'ondelettes pour représenter les caractéristiques locales et couper le signal du domaine temporel en différentes composantes de fréquence en appliquant une analyse multi-résolution lors de l'application de l'entropie multi-échelle des courants des phases. Nous utilisons une variété de tailles de fenêtre déterminant la résolution figures (4.18-4.20), (détail D1-D5). Différentes tailles des fenêtres sont utilisées lors de l'application DWT-MSE puisque les oscillations sont plus lentes par rapport au signal haute fréquence (figure 4.10) nécessitant des fenêtres de plus petite taille figures. (4.18-4.20), (détail D4-D5). Ce processus est répété plusieurs fois avec la fenêtre légèrement plus courte pour chaque nouveau cycle. En fin de compte, le résultat est un ensemble de représentations temps fréquence des signaux à travers MSE à différentes résolutions. L'ondelette mère utilisée était le Daubechie (db4) puisqu'elle a abouti à une trame d'énergie interne semblable à la répartition des défauts d'engrenages, car elle est plus sensible aux variations d'amplitude dans un signal de contrainte. Des segments fortement endommagés par défaillance à travers l'application DWT-MSE dans les différents cas d'études ont été extraites, sur la base d'une distribution d'énergie élevée (figure 4.6). Afin de provoquer des segments contribuant à des dommages des défaillances d'engrenages, la valeur de la porte d'énergie, qui est la variable du spectre d'énergie, a ensuite été appliquée comme paramètre dans notre cas d'étude pour déterminer le niveau de magnitude minimum à retenir dans le domaine d'ondelettes.

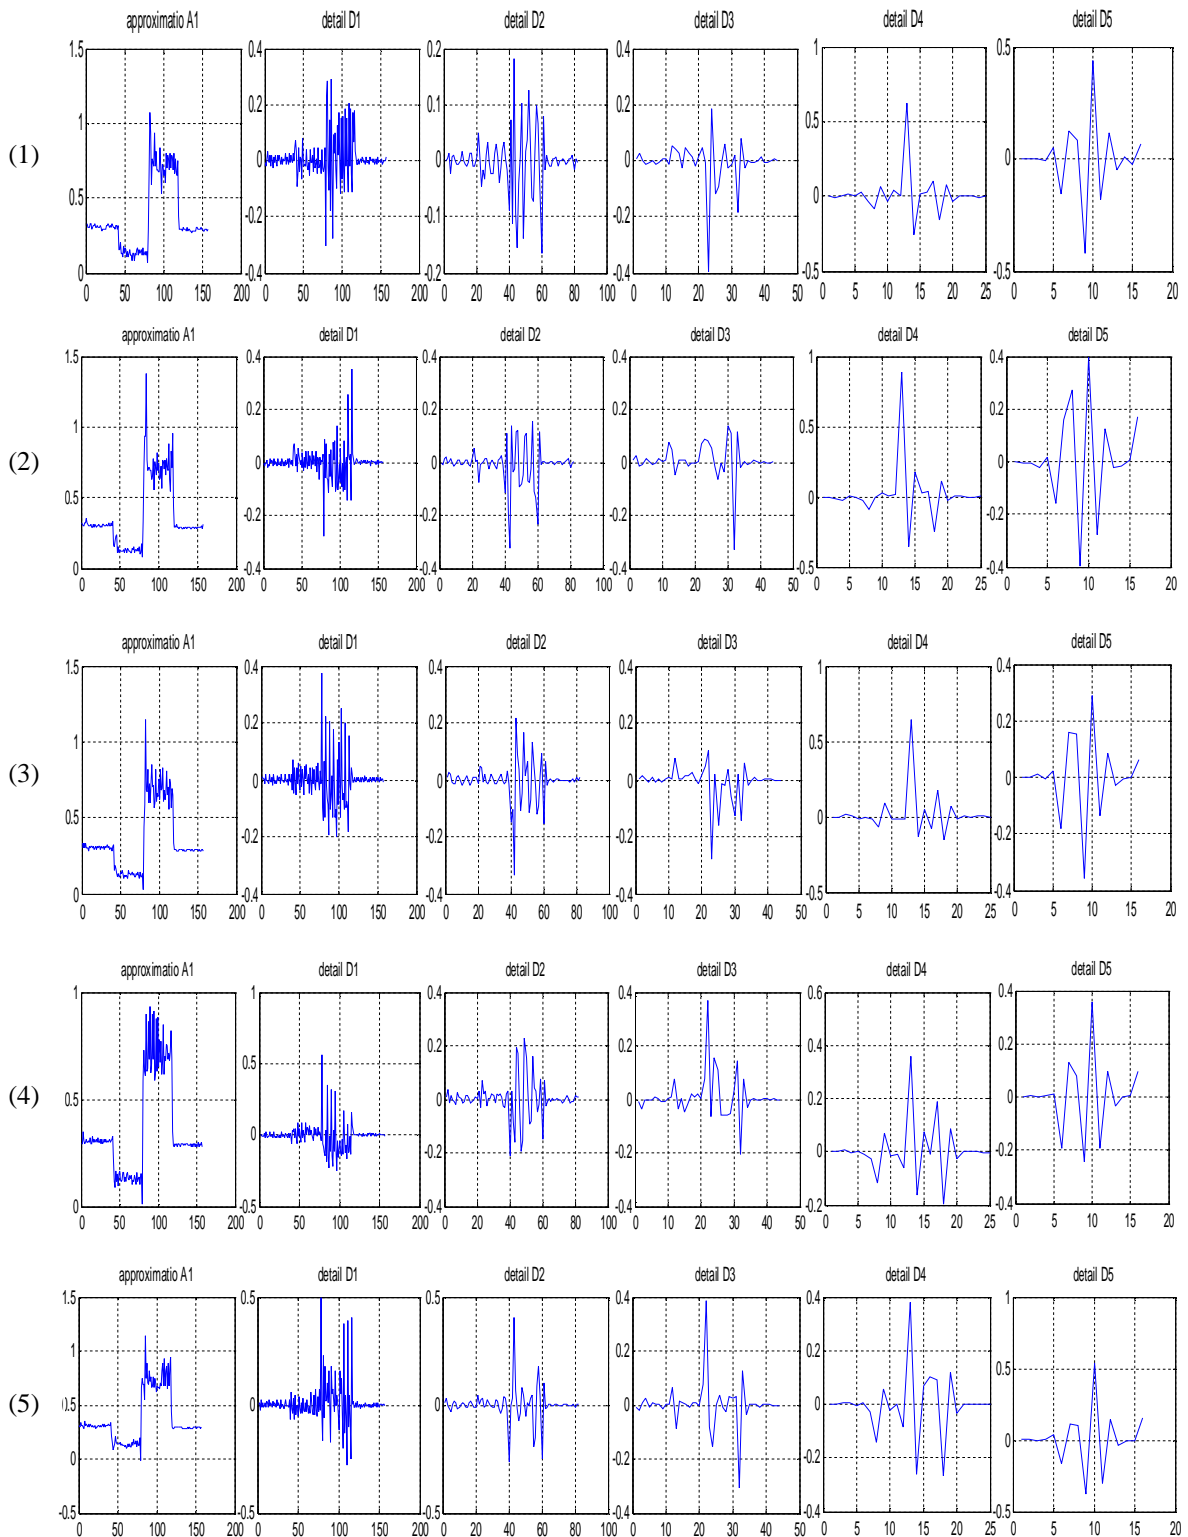


Figure 4.18- Evolutions des différentes décompositions en ondelettes pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.12).

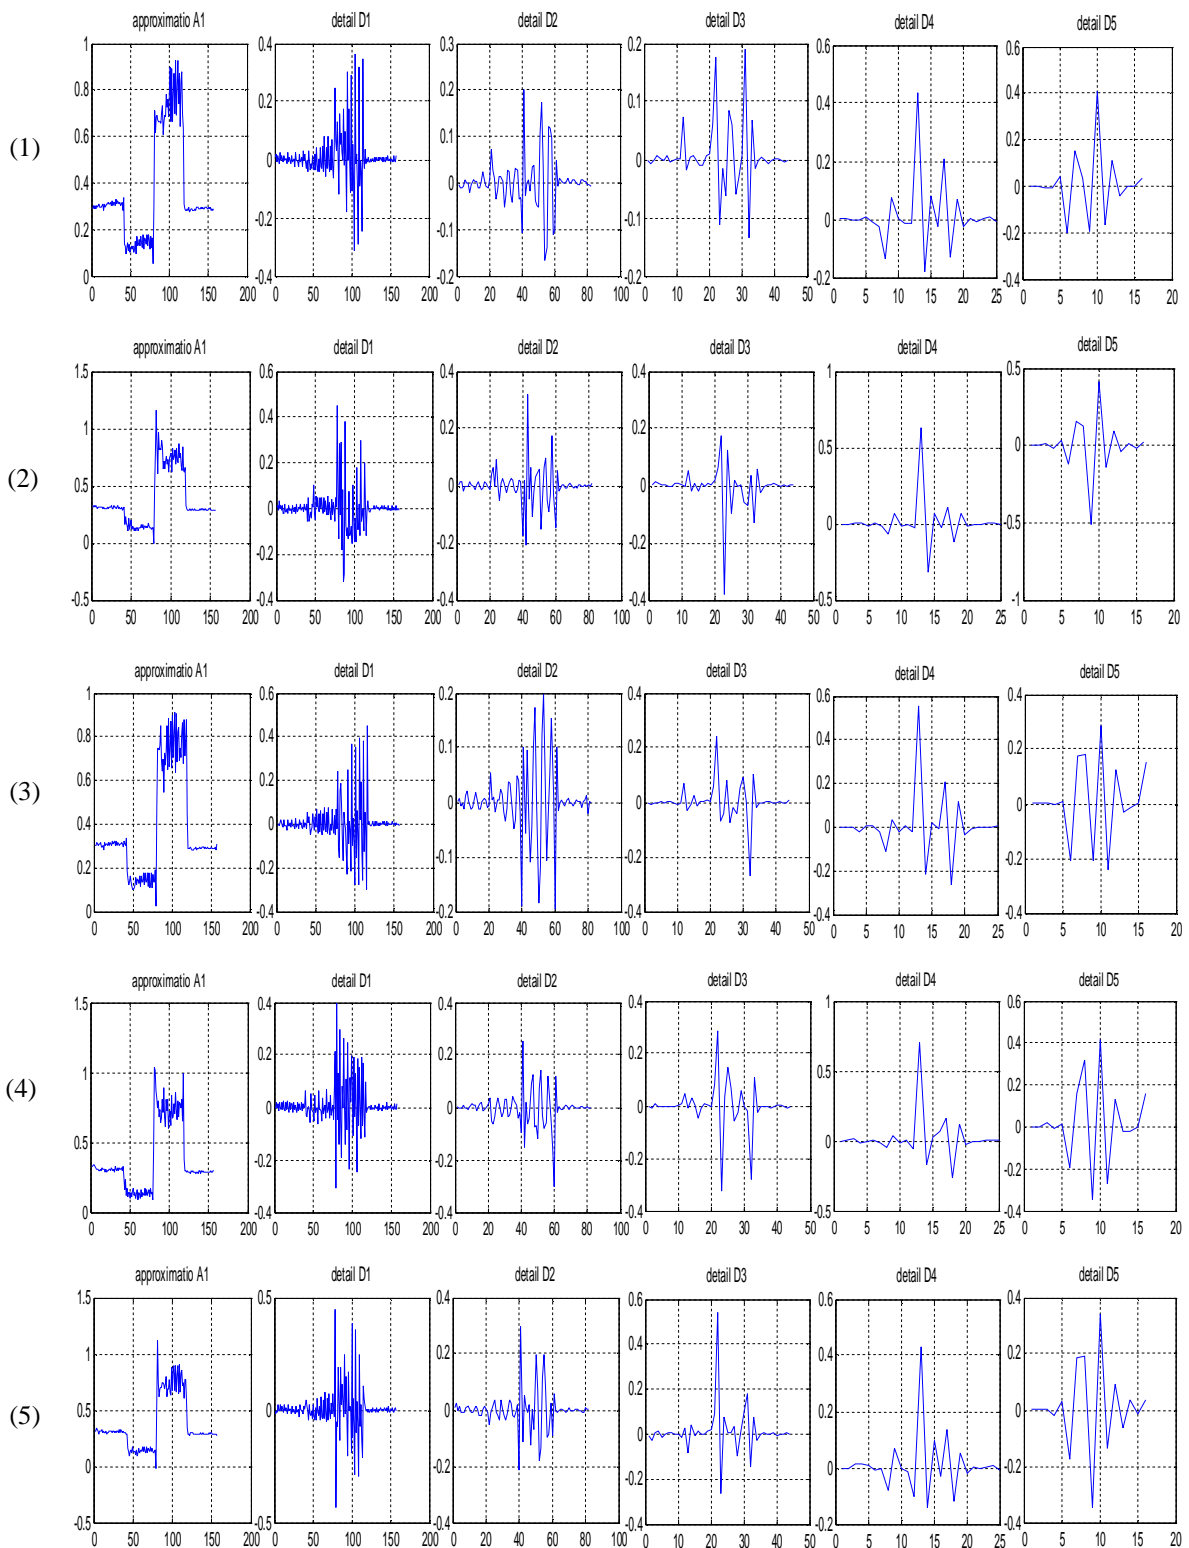


Figure 4.19- Evolutions des différentes décompositions en ondelettes pour les quatre statistiques au cours de MSE du signal de courant de phase IB (illustré par la figure 4.13).

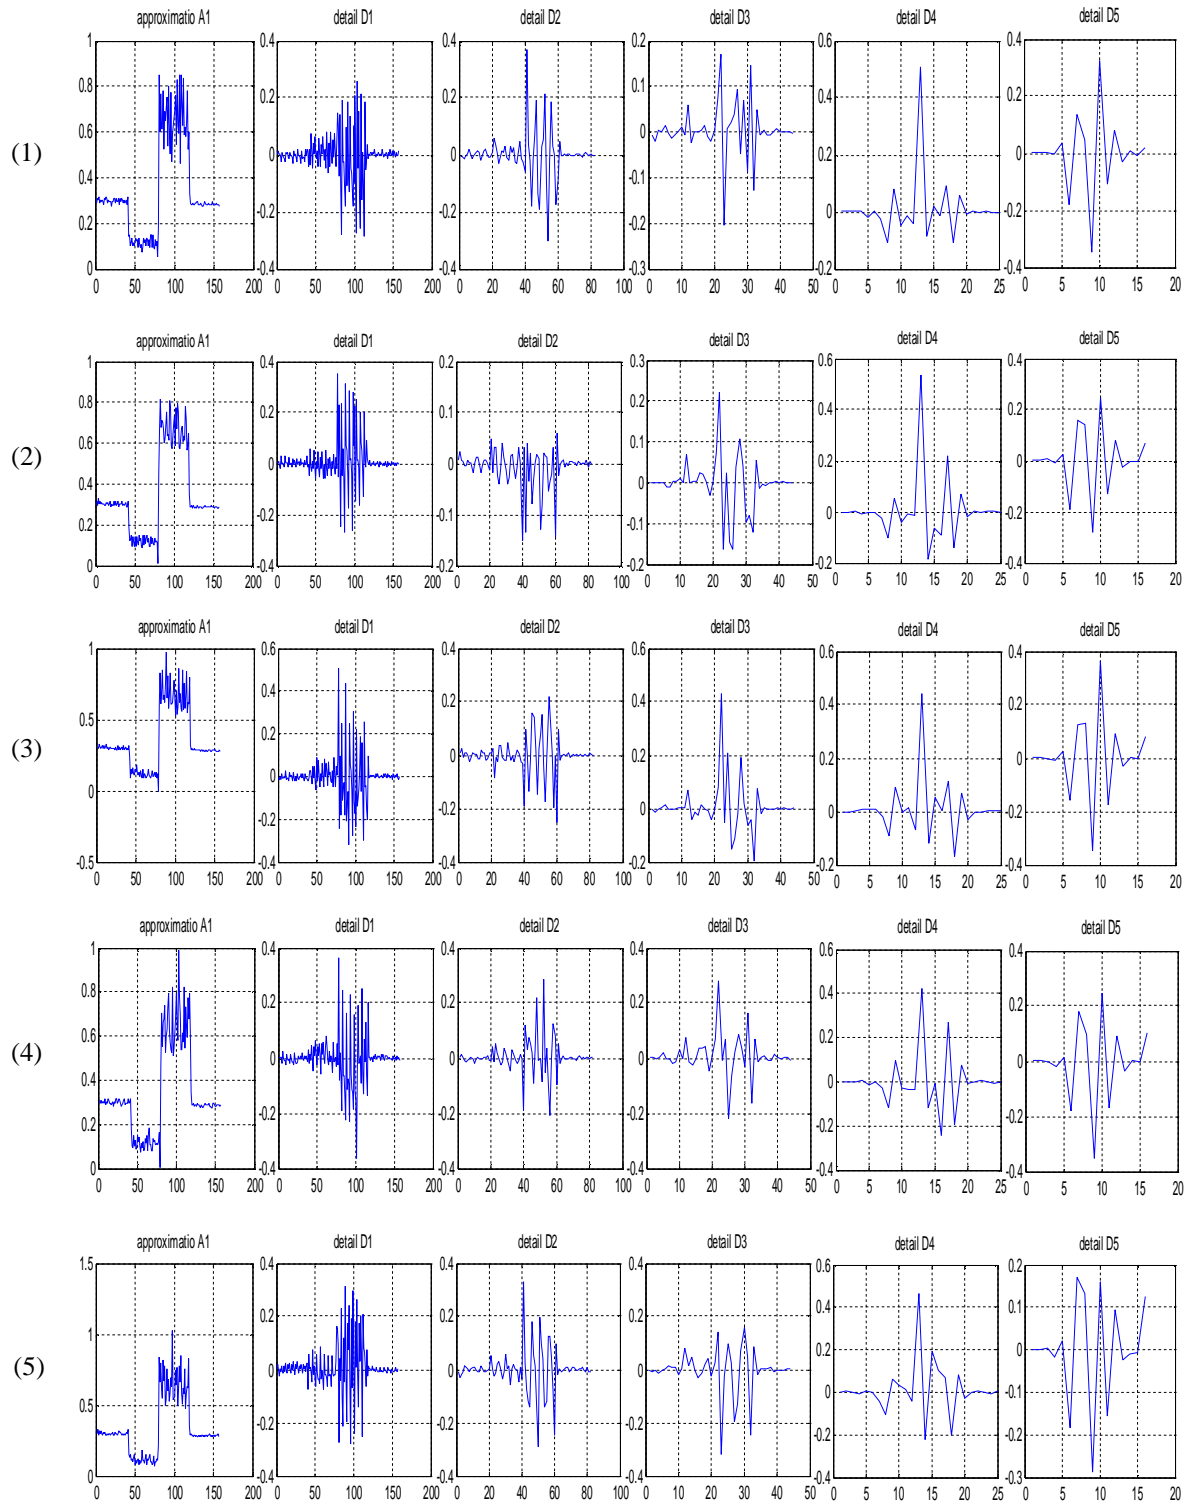


Figure 4.20- Evolutions des différentes décompositions en ondelettes pour les quatre statistiques au cours de MSE du signal de courant de phase IC (illustré par la figure 4.13).

4.10 Détection des défaillances en utilisant des indices de détection

La procédure de détection des défaillances commence par la mesure de la variable courante dans chaque phase de courant statorique. Les valeurs acquises sont transmises par le biais d'une transformation linéaire ACP pour extraire les composantes principales et de réduire le bruit de mesure. Les statistiques de détection des valeurs aberrantes sont alors calculées pour surveiller la variable courante pour les valeurs anormales. Après la construction du modèle ACP qui représente le comportement du système en fonctionnement normal, la nouvelle observation est projetée sur le nouvel espace. Elle sera caractérisée par les indices statistiques les plus populaires utilisés pour la détection des défauts sont : SPE (dans le sous espace résiduel) et T^2 (dans le sous-espace des composantes principales) et la combinaison des deux indices. Elles sont données par [8]:

4.10.1 Erreur de prédiction au carré SPE :

$$SPE = \|\tilde{x}\|^2 = x^T \tilde{P} \tilde{P}^T x = x^T \tilde{C} x \quad (4.33)$$

Avec une limite de contrôle δ^2 qui définit comme suit :

$$\delta^2 = g^{SPE} x_\alpha^2 (h^{SPE}) \quad (4.34)$$

Avec $(1-\alpha) \times 100\%$ niveau de confiance et avec :

$$g^{SPE} = \frac{\theta_2}{\theta_1} \quad (4.35)$$

$$h^{SPE} = \frac{\theta_1^2}{\theta_2} \quad (4.36)$$

Où $\theta_1 = \sum_{i=l+1}^m \lambda_i$, $\theta_2 = \sum_{i=l+1}^m \lambda_i^2$ et λ_i est le i^{th} valeur propre de la covariance S .

4.10.2 Statistique T^2 de Hotelling :

La variation d'un processus dans PCs est mesurée par l'index T^2 est défini comme:

$$T^2 = t^T \Lambda^{-1} t = x^T P \Lambda^{-1} P^T x = x^T D x \quad (4.37)$$

Le processus est considéré comme normal si $T^2 \leq \tau^2$ et la limite de contrôle τ^2 est :

$$\tau^2 = x_\alpha^2(l) \quad (4.38)$$

Avec $(1-\alpha) \times 100\%$ niveau de confiance.

Nous avons utilisé l'analyse en composantes principales pour modéliser le comportement de notre système pendant les deux phases de fonctionnement du système, cependant en comparant le comportement observé et celle donnée par le modèle de ACP pour but de diagnostic le fonctionnement de système étudié (voir Figure 4.21 et Figure 4.22).

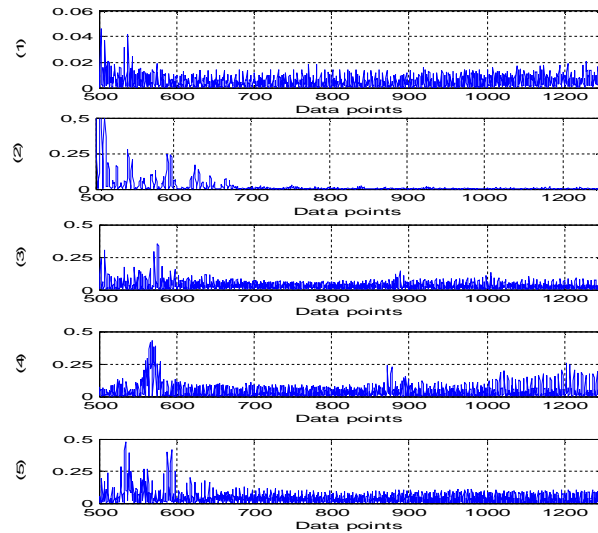


Figure 4.21- Evolutions des différents SPE du signal norme de courant Stator pour l'état sain et les différents cas des défaillances (Figure 4.3).

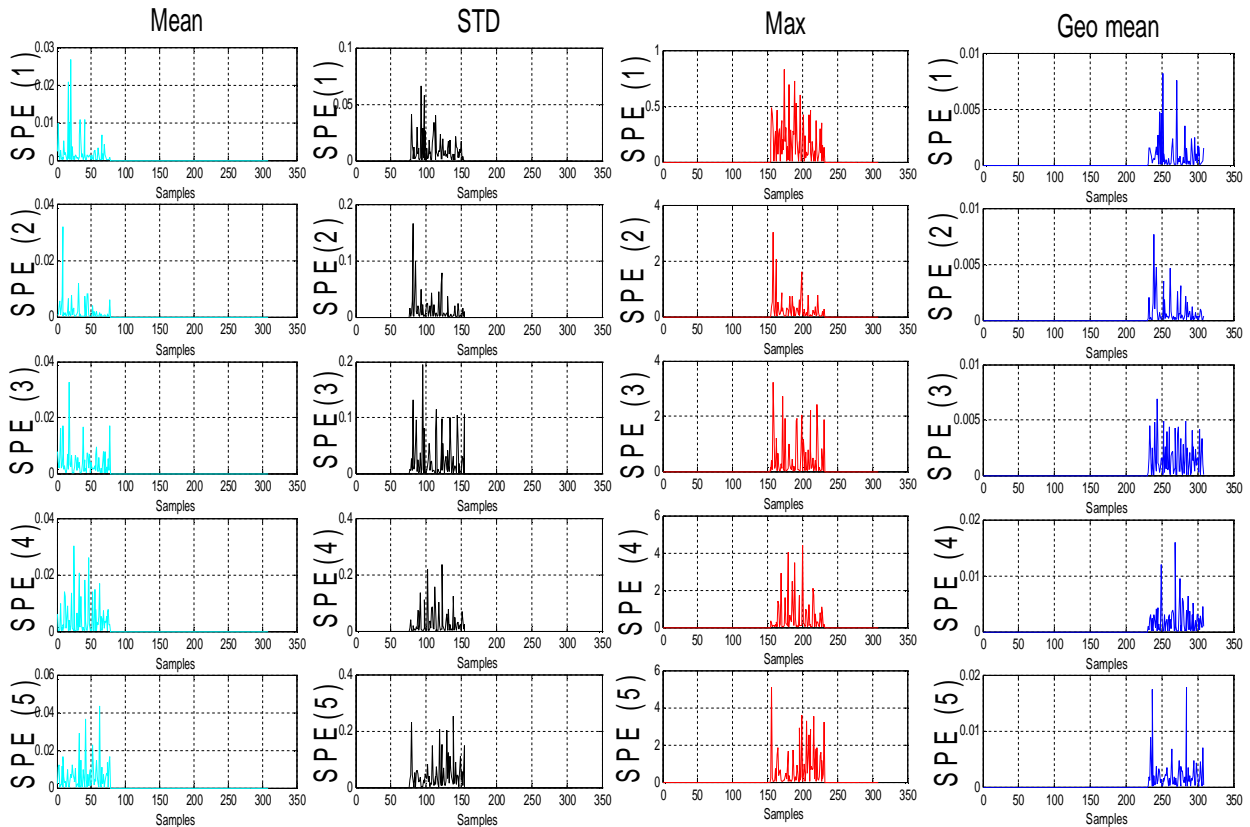


Figure 4.22- Evolutions des différents SPE pour les quatre statistiques au cours de MSE du signal de courant de phase IA pour: (1) l'état sain et (2-5) les défaillances affectant les différents cas (Figure 4.3).

A partir de la figure 4.21 on constate que le SPE globale n'est pas un test efficace pour la détection lorsqu'on l'applique directement sur les courants des phases statoriques de la machine à induction, par contre il donne des bons résultats lorsqu'on l'applique sur les différents indicateurs de MSE (figure 4.22). Si la boîte de vitesses continue à fonctionner

dans un état normal, le tableau SPE pour un engrenage sain montrera peu de fluctuation comme le montre la figure 4.22 (1). Cependant, quand une défaillance locale commence à se développer dans une dent, la SPE fluctue considérablement et certains pics commencent à apparaître comme illustré sur la figure 4.22 (2-4). Les pics apparaissent cohérents dans la même région à une défaillance locale de croissance, ce qui indique que l'emplacement du défaut dans l'engrenage est supérieur qu'avant figure 4.22 (5). Il a été démontré que bien que la (SPE approximation A1, T^2 - Approximation A1 and T^2 -Detail D1) soit suffisante pour détecter toute modification de la condition de fonctionnement et la sensibilité des indicateurs des défaillances dépend fortement des caractéristiques de couplage [127].




Figure 4.23- Evolutions des différents SPE Approximation A1 pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.20).




Figure 4.24- Evolutions des différents T^2 -approximation A1 pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.20).




Figure 4.25- Evolutions des différents T^2 -detail D1 pour les quatre statistiques au cours de MSE du signal de courant de phase IA (illustré par la figure 4.20).

La décomposition en ondelettes est appliquée dans l'entropie multi-échelle (MSE) de la (MCSA), les signaux sont projetés sur approximation et le détail des coefficients. Le coefficient d'approximation est un signal à basse fréquence qui contient les caractéristiques importantes déterministes sous-jacentes. Les fonctions détaillées contiennent des signaux de haute fréquence comme indiqué sur les figures (4.18-4.20).

La performance de surveillance en utilisant SPE-(valeur maximale, valeur moyenne arithmétique, moyenne géométrique et la valeur de l'écart type) offre de bons résultats comme le montre (figure 4.22) par rapport à la multi-échelle (SPE-MSE & T^2 -MSE) comme représenté en Figures (4.23-4.25). En comparant les figures 4.23-4.25 on constate qu'aucun de ces défauts n'a été facilement détecté par la statistique T^2 -approximation A1 et T^2 -detail D1. En réalité la statistique SPE Approximation A1 est utilisée comme un indice fiable pour la détection des défaillances.




Figure 4.26- CDFs de MCS mesurées de toutes les conditions défectueuses.

La figure 4.26 décrit le comportement statistique de l'indice de défaillance en utilisant la fonction de distribution cumulative (CDF) et par CDFs de comparaison qui peuvent être utilisés pour l'identification des défauts des dents sur les engrenages, la CDF d'une bonne santé, dans le cas d'un couplage rigide est suffisamment éloigné. Les performances des joints utilisés pour assurer l'accouplement flexible affecte de manière significative la réponse dynamique de la machine à induction entraînant la boîte de vitesses (mesures effectuées avec différentes conditions de charge et sans charge, (Figure 4.27). Accouplement flexible serait grandement modifier les couples dynamiques sur le moteur et donc les courants résultant [100], nous pouvons conclure de nos résultats que le couplage rigide de côté précision de fonctionnement est mieux comparé avec l'accouplement flexibilité de point de vue du mécanisme de couplage.

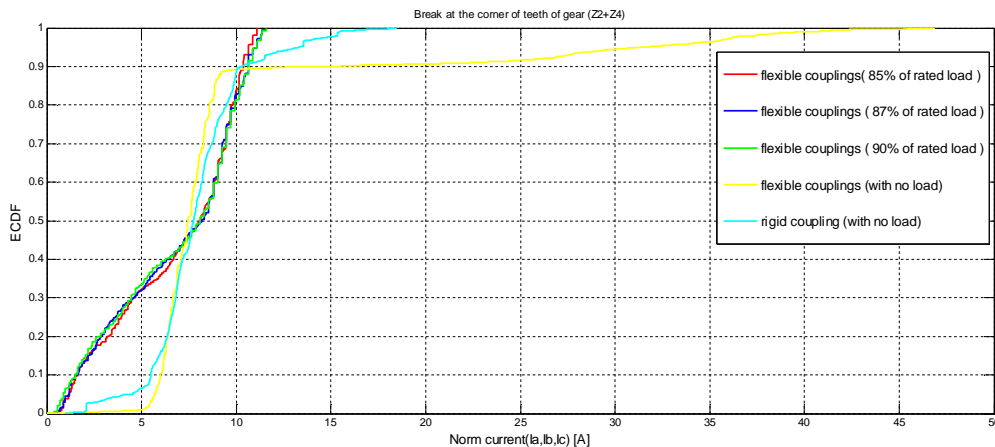


Figure 4.27- CDFs de MCS mesurées de toutes les conditions défectueuses en cas des différents d'études dans le cas d'un couplage rigide et accouplement flexible.

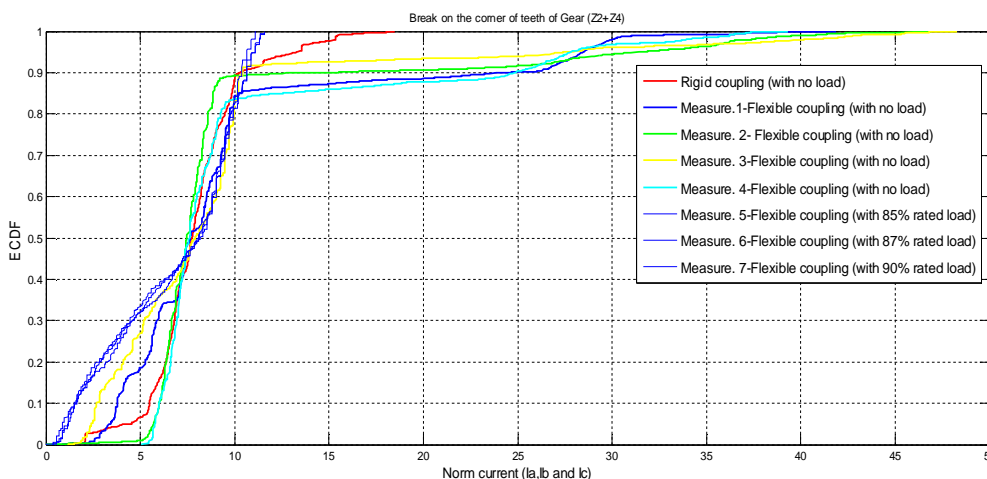


Figure 4.28- CDFs de MCS mesurées de toutes les conditions défectueuses en cas différents d'études dans le cas d'un couplage rigide et différentes mesures d'accouplement flexible.




Figure 4.29- Zoom sur CDFs de mesure MCS de toutes les conditions défectueuses en cas différents d'études dans le cas d'un couplage rigide et différentes mesures d'accouplement flexible.

Le CDF du courant de norme dans le cas d'un couplage rigide se caractérise par une lente roll-off du lobe principal (figure 4.29). L'ampleur de la réponse CDFs de la liaison élastique est plate. Par conséquent, l'accouplement flexible compense l'erreur d'alignement par rapport au couplage rigide.

4.11 Conclusions


Ce travail expérimental a présenté les performances de l'analyse technique des signaux de courant et de son potentiel pour surveiller et diagnostiquer les engrenages des transmissions entraînées par machine à induction. Une approche de diagnostic de la défaillance des dents de réducteur de vitesses a été développée sur la base de MCSA utilisant l'entropie multi-échelle (MSE) et de l'approche de classification. MSE sur 20 échelles sont extraits de manière à tenir compte de la non-linéarité dynamique, ainsi que les effets de couplage et d'interaction entre les pièces électromécaniques. Quatre statistiques plus MSE sont présentées pour une approche de classification des défauts et utilisées pour les statistiques multivariées approche. L'évaluation de la complexité du signal de sous-échantillonné est sollicité par l'inclusion de ces éléments artefactuels. Cette lacune a été analysée par PCA-MSE, ainsi que par la fonction cumulative empirique de distribution (ECDF) que les techniques d'analyse. L'hypothèse alternative est supposée ici que tout changement de défaut ou condition de charge de la boîte de vitesses va changer CDF (pente dans la région de transition), par conséquent, il y a une comparaison dans le remplacement de l'assemblage rigide avec l'accouplement flexible, bien qu'une liaison élastique soit utile.

ANNEXE

TABLE IV.1

LES PARAMETRES ELECTRIQUES DE LA MACHINE A INDUCTION

INDUCTION MACHINE	
Power	3kW
Phase	Tree Phase
Ω_1 =Speed Rating	960 rpm
number of poles	2 poles
Frequency Rating	50 Hz
Voltage Rating	380V
Full Load Current	7.2 A



A

Figure 4.30- Accouplement flexible.

TABLE IV.2

Matériels de l'accouplement utilisé.

7	Partie 1	1	Acier
6	Joint plat	6	Plastique
5	Tête Hex. H	6	Acier
4	Partie 2	1	Acier
3	Ecrou Hex.	6	Acier
2	Joint plat	2	Plastique
1	Tube	6	Plastique
N°=	Désignation	Nbr	Matériel

**Deuxième Partie : Diagnostic de défauts des capteurs
des différentes concentrations des gaz présents dans la
synthèse de l'ammoniac basée sur l'entropie multi-
échelle et Statistiques multivariées**

Sommaire

4.13	Introduction	88
4.14	Méthodologie et outils.....	98
4.15	Conclusion.....	93

4.13 Introduction

La philosophie générale de l'ingénierie derrière les nouvelles technologies de l'ammoniac est d'employer plus des pressions dans la section de reforming où le mélange H_2 et N_2 préparé à une pression plus basse dans la section de synthèse d'ammoniac [3]. Les compresseurs centrifuges sont entraînés par des turbines à vapeur ou à gaz. Le vapeur d'eau est généré par l'utilisation de la chaleur sensible à partir de les produits gazeux du convertisseur de synthèse et de reforming secondaire, ainsi que la chaleur perdue à partir de gaz principal de combustion de reforming. Bien qu'un grand avantage de la nouvelle conception est d'obtenir une utilisation extrêmement efficace de la chaleur générée dans l'installation, son fonctionnement est très sensible à la fois au processus de la performance de l'équipement. Le succès de la nouvelle technologie de l'ammoniac a été marqué par la reconnaissance insuffisante des interactions des plantes et par la tenue mécanique d'une partie de l'équipement, tel que les compresseurs centrifuges dont l'efficacité diminue avec le temps et la surcharge de la production de vapeur de l'usine. Afin de comprendre ces interactions représentées sur le processus étudié nous étudions l'effet des actions des contrôleurs pour surveiller le rapport H_2 / N_2 sur la boucle de synthèse. Deux mesures correctives distinctes pourraient être prises pour atteindre cet objectif. On peut régler le purgeur de débit dans la boucle de synthèse, tandis que la seconde action peut être le changement de débit d'air pour une durée limitée de temps qui implique la modification de rapport H_2 / N_2 dans le flux de compresseur de synthèse de l'ammoniac. La variation du taux de purge va mettre en place une température de perturbation dans la section de reforming primaire ainsi que la température des gazes dans le four, cette perturbation de température est en outre, transmise à la section de reforming secondaire. Le changement de fonctionnement du compresseur peut, d'autre part causer des troubles de pression et de circulation des flux massiques dans la section de réfrigération. Ces différents troubles peuvent lentement s'accumuler dans les différentes sections de l'ammoniac d'usine. Un changement de flux d'air provoque une variation de température dans le gaz de la section de reforming secondaire, ces perturbations vont passer à la section de synthèse et retour vers le reforming primaire. Il est convenable alors, qu'une seule corrective action dans la section de synthèse peut entraîner des perturbations dans l'installation d'usine et provoquant divergentes problèmes de stabilité. Si, en revanche, aucune action corrective n'est apportée à l'action réactive est prise pour compenser cette perturbation dans la composition du gaz de synthèse.

Dans cette partie, nous proposons une méthode pour surveiller les capteurs de différentes concentrations de gaz présents dans la synthèse de l'ammoniac basée sur l'entropie multi-

échelle (MSE) et construire un modèle de l'ACP qui peut suffisamment fournir des informations pertinentes sur les variables de processus et sur la stabilité du réacteur. La stabilité du fonctionnement du réacteur peut être caractérisée par sa réponse à la variation d'un paramètre de régime.

4.14 Méthodologie et outils

Comme on le voit sur la figure 1, les variables sont fortement corrélées, ce qui signifie qu'ils varient ensemble. Cette redondance dans les mesures nous permet l'intérêt de l'inspection des différents gaz basé sur l'entropie multi-échelle et l'approche ACP afin d'analyser la non linéarité existant dans ces variables. MSE fait référence au calcul des entropies à travers une séquence d'échelles, qui prend en compte non seulement la non-linéarité dynamique mais aussi les effets de l'interaction et de couplage entre les processus d'ammoniac, offrant ainsi beaucoup plus d'informations concernant les processus.

Les données ont été collectées à partir de l'usine de fertilisation (Fertial Spa-Annaba). La documentation de processus a été fournie par KBR.

La recherche suit ces étapes:

- CH₄ S (101B), CO S (HTS), CO S (LTS), CO₂ (106D) et H₂ (105D) ont été enregistrées à partir de processus d'ammoniac.




Figure 4.31- Les différents variables enregistrés.




Figure 4.32- MSE au cours de 20 échelles du signal de courant de stator correspondant est représenté en figure. 4.30.




Figure 4.33- Cinq statistiques au cours de MSE du signal de courant de phase est représentées sur la figure 4.31.

L'entropie multi-échelle est utilisée pour inspecter les différents gaz présents dans la synthèse de l'ammoniac, MSE à travers 20 échelles sont calculées pour former un ensemble d'entités contenant des informations riches sur l'état indiquant l'évolution des concentrations des différents gaz présents dans la synthèse. Cinq paramètres sont extraits de l'ensemble des

caractéristiques d'origine, qui sont la valeur maximale, valeur minimale, valeur moyenne arithmétique, moyenne géométrique et la valeur de l'écart type.

Figure 4.34 donne le MSE à travers 20 échelles correspondant aux signaux représentés sur figure 4.33. A partir de la figure 4.34, on peut voir que l'erreur quadratique moyenne des différents gaz varie ensemble n'a pas les plus grandes valeurs d'entropie sur la plupart des échelles par rapport à l'autre, ce qui signifie que la concentration des différents gaz présents dans la synthèse de l'ammoniac se stabilise à travers le même point de fonctionnement dans les différents gaz présents dans la synthèse de l'ammoniac.

Afin d'estimer les concentrations des différents gaz présents dans la synthèse de l'ammoniac, nous utilisons pour modéliser le processus l'approche ACP est proposé représenté dans les figures 4.36 et 4.37.




Figure 4.34- Mesures et estimations du CO S (HTS).




Figure 4.35- Mesures et estimations du CO₂ (106 D).

TABLE IV.3

CONTROLE DES PARAMETRES DE PROCESSUS

Mesures	Valeurs
CH ₄ S (101D)	(101B) <11%
CO S(HTS)	(HTS) <6 %
CO S(LTS)	(LTS) <0.5%
CO ₂ S (106D)	(106D) < 12 PPM
H ₂ (105D)	55%-70%

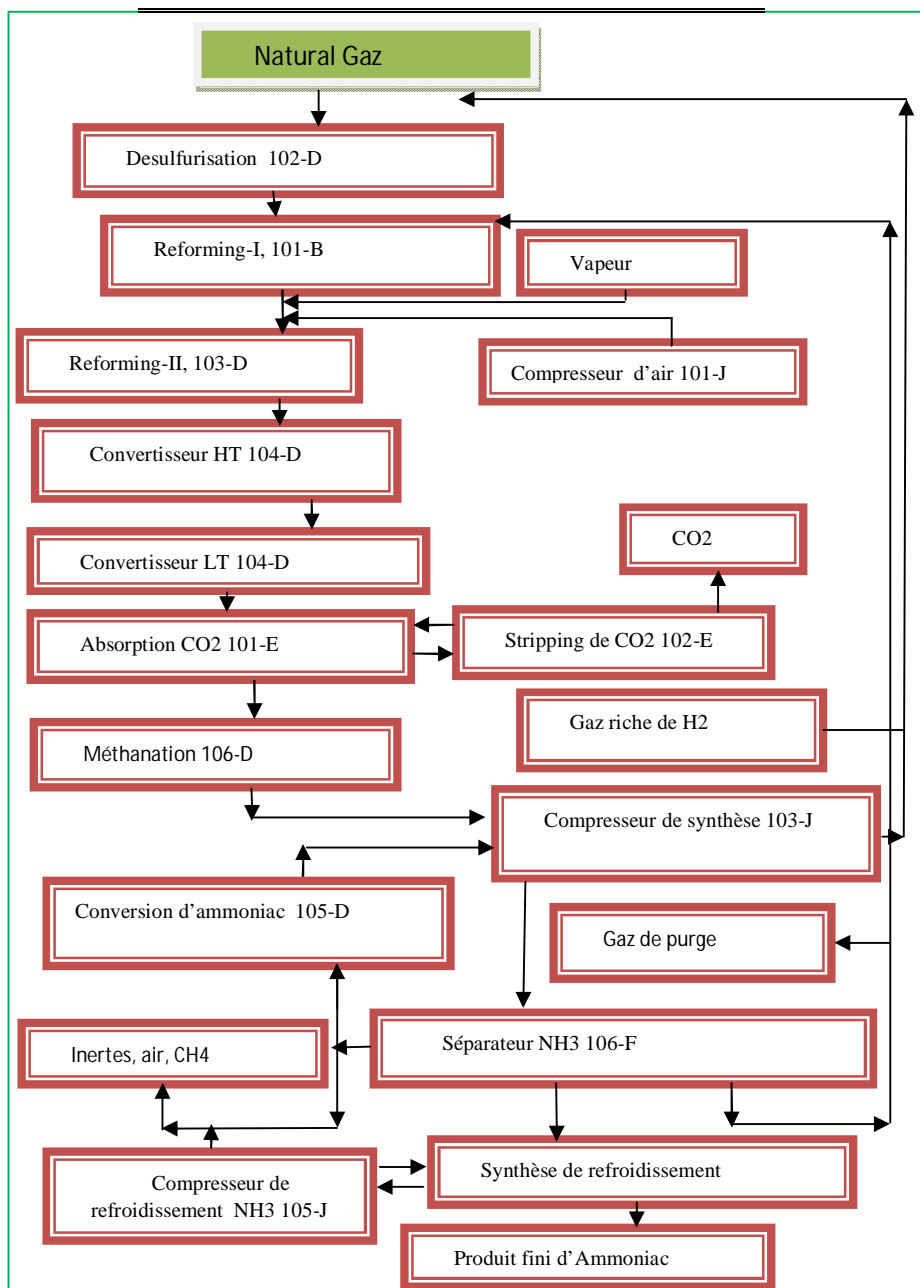


Figure 4.36- Schéma de principe du procédé de synthèse de l'ammoniac.

Afin de comprendre ces interactions, décrites dans le schéma de Figure 4.37, laissez-nous voir par exemple l'effet des actions de l'opérateur pour régler ou contrôler le: ration dans la boucle de synthèse (le gaz désulfuré en mélange avec la vapeur de moyenne pression dans une vapeur / gaz naturel = 1/3. comme indique la figure 4.38).




Figure 4.36- Mesures vapeur / gaz naturel.

4.15 Conclusion

La surveillance en temps réel et le contrôle des variables de la qualité des produits jouent un rôle essentiel dans le processus dû chimique aux spécifications élevées et bien définies nécessaires pureté et l'amélioration de la contrôlabilité de ces variables. Un aspect important de la sécurité de fonctionnement processus chimique est la détection rapide des défaillances, perturbations du procédé, ou d'autres événements spéciaux et l'emplacement et l'élimination des facteurs à l'origine de tels événements. Cependant, des centaines de variables peuvent être contrôlées dans une unité d'exploitation unique, et ces variables peuvent être enregistrées sur des centaines ou des milliers de fois par jour. En l'absence du procédé de traitement approprié, que des informations limitées peuvent être extraites à partir de ces données. Par conséquent, un outil est nécessaire qui peut projeter l'espace de grande dimension processus en un espace de petite dimension prête à la visualisation directe, et qui peut également identifier les variables clés et caractéristiques importantes des données. La nécessité d'analyser les données de grande dimension et de corrélation processus a conduit au développement de nombreux systèmes de surveillance basés sur analyse en composantes principales ACP comme technique de modélisation qui transforme un ensemble de variables corrélées dans un ensemble plus restreint de nouvelles variables qui ne sont pas corrélées et conservent la plupart des informations d'origine. L'entropie multi-échelle est utilisée pour inspecter les différents gaz présents dans la synthèse de l'ammoniac.

Conclusions et Perspectives

Conclusions

L'utilisation des techniques de redondance analytique repose sur la disponibilité d'un modèle du système ou sous-système assemblant les entrées et les sorties mesurées, avec une exploitation optimale de toutes les informations acquises. Le besoin d'analyse et de synthèse des données corrélées de processus de grande dimension a conduit au développement de nombreuses approches de surveillance s'articule sur l'analyse statistique multivariée. Un de nos objectifs a été d'utiliser l'analyse en composantes principales ACP pour la mise en évidence des corrélations linéaires significatives entre les variables des processus sans formuler de façon explicite le modèle du système. Toutes les corrélations entre les différentes variables sont prises en compte dans le modèle ACP. Ainsi pour but principal de détection et localisation de défauts dans les systèmes électro-énergétiques. L'ACP est employée pour modéliser le comportement du processus en fonctionnement normal et les défauts sont alors détectés en comparant le comportement observé et celui donné par le modèle. L'ACP permet de générer un modèle de processus basé sur la connaissance issue du système sans avoir une forme explicite d'un modèle entrées/ sorties. Ainsi elle permet d'exploiter toutes les relations linéaires qui peuvent exister entre les différentes variables. Avant tout, nous avons présenté le principe de l'analyse en composantes principales linéaire ACP ainsi l'extension de l'ACP dans le cadre non-linéaire ACPNL. Pour la détermination de la structure du modèle, il faut déterminer les nombres de composantes principales à retenir dans le modèle. Pour cela plusieurs critères ont été présentés pour but de sélection du nombre de composantes. L'étude que nous avons menée dans cette thèse porte sur le diagnostic des systèmes non linéaire par l'analyse statistique multivariée. Une fois le modèle ACP linéaire ou ACP non linéaire construit, les défauts peuvent être détectés par les indicateurs statistiques de détection articulant sur l'espace résiduel et l'espace principal ou entre les deux espaces.

L'indice SPE est très sensible aux erreurs de modélisation est englobe les erreurs de chacun des résidus ou des indicateurs de comportement des variables. L'indice T^2 ne peut être utile surtout lorsqu'on utilise cet indice seule pour la détection et la difficulté d'interprétation des résultats obtenus. Pour ces raisons, nous avons proposé d'utiliser un nouvel indice basé sur les dernières PCs en conjonction avec des règles de détection.

Conclusions et Perspectives

Après avoir détecté la présence de défauts, il est nécessaire de localiser la ou les variables défectueuses. Différentes approches de localisation ont été exposées et nous avons présenté la structuration des résidus dans le cas d'ACP et avec conjointement des autres méthodes (l'entropie multi-échelle et la décomposition en ondelettes) ainsi la procédure de détection et localisation par cette nouvelle technique MSE qui offre une possibilité d'utiliser des indicateurs partiels et pour explorer la complexité des systèmes électro-énergétiques. Cette dernière nous donne une interprétation des importantes oscillations, qui affectent l'analyse MSE pour les différentes séquences des différent cas d'études dans notre application d'étude. Différentes observations nous exigés d'utiliser l'analyse multi-résolution en ondelettes qui a été proposée dans le but du diagnostic des systèmes électro-énergétiques. Le filtrant des bruits a été réalisé pour n'avoir uniquement que la signature de défaut. L'analyse en MSE avec l'analyse en ondelettes grâce à ses grandes propriétés, semblaient les plus intéressante à appliquer.

Dans le dernier chapitre nous avons présenté les deux applications des méthodes proposées.

La première application comporte à utiliser de l'entropie multi-échelle & l'analyse en composantes principales ainsi la décomposition en ondelettes pour but de diagnostic & détection de défauts des engrenages par l'analyse de la signature du courant moteur. Et l'interprétation des résultats obtenus à l'aide des statistiques multivariées.

La deuxième application sera consacré à discuter les relations entre les différentes variables des processus les approches de diagnostic.

Perspectives

Amélioration de la qualité du modèle ACP non linéaire et nous proposons d'utiliser des algorithmes combinant différentes approches avec la prise en compte des procédures d'optimisations.

Une perspective de ce travail consiste à automatiser la procédure de diagnostic et détection de défauts avec l'optimisation des paramètres utilisés dans l'algorithme pour tenir compte des caractéristiques des signaux présents dans l'environnement industriel.

Références bibliographiques

- [1] E Y. Chow and A.S. Willsky, “Analytical Redundancy and the Design of Robust Failure Detection Systems,” *IEEE Transactions on Automatic Control*, vol. AC-29, pp.689-691, 1984.
- [2] A. Maulud, D. Wang, and J.A. Romagnoli, “A multi-scale orthogonal nonlinear strategy for multi-variate statistical process monitoring,” *Journal of Process Control*, Vol. 16, pp. 671-683, 2006.
- [3] Aouabdi.S,& Taibi.M,”Sensor Monitoring of the Concentrations of Different Gases Present in Synthesis of Ammonia Based On Multi-Scale Entropy and Multivariate Statistics,”*World Academy of Science, Engineering and Technology, International Journal of Environmental, Chemical, Ecological, Geological and Geophysical Engineering*, Vol.09,No.02, pp.169-172, 2015.
- [4] E.B.Martin,A.J.Morris and J.Zhang,”Process performance monitoring using multivariate statistical process control,” *IEE Proceedings, control theory and application*, Vol.143,No.02, pp.132-144,2000.
- [5] Manish Misra, H. Henry Yue,S. Joe Qin, Cheng Ling, “Multivariate process monitoring and diagnosis by multi-scale PCA,” *Computers and Chemical engineering*, Vol. 26, pp. 1281–1293, 2002.
- [6] Anissa BENAICHA, Gilles MOUROT, Kamel BENOTHMAN and José Ragot,” Determination of principal component analysis models for sensor fault detection and isolation,” *International Journal of Control, Automation, and Systems*, Vol. 11, No 2, pp. 296-305.2013.
- [7] H. Abdi & L. J. Williams, Principal component analysis, *Wiley Interdisciplinary Reviews: Computational Statistics*, Vol. 2, No. 4, pp. 433-459, 2010.
- [8] Carlos Alcalá and S.Joe Qin, "Reconstruction- based Contribution for Process Monitoring," *Proceedings of the 17 th world congress, (the IFAC'08), Seoul Korea*, July 6-11, 2008.
- [9] S. Joe Qin, Ricardo Dunia, “Determining the number of principal components for best reconstruction,” *Journal of process control*, Vol. 10, pp. 245–250, 2000.

Références bibliographiques

- [10] Ricardo Dunia, S. Joe Qin, Thomas F. Edgar and Thomas J. McAvoy, "Use Of Principal Component Analysis For Sensor Fault Identification," *Computers Chem. Engng.* Pergamon, Vol. 20, pp. S713–S718, 1996.
- [11] Anissa Benaïcha, Gilles Mourot, Kamel Benthman and José Ragot, "Determination of Principal Component Analysis Models for Sensor Fault Detection and Isolation," *International Journal of Control, Automation, and Systems*, Vol. 11, pp. 296–305, 2013.
- [12] Karim Salahshoor, Fariborz Kiasi, "On-line process monitoring based on wavelet-ICA methodology," *Proceedings of the 17 th world congress, IFAC*, pp. 7413–7420, 2008.
- [13] I.T. Jolliffe, *Principal component analysis*, Books, Second edition, Springer series in statistics, 1986.
- [14] J. D. Leeuw, "Information theory and an extension of the maximum likelihood principle by hirotogu akaike," in *2nd International Symposium on Information Theory*, 1973.
- [15] Hirotugu AKAIKE, "A new look at the statistical model identification," *IEEE Transactions on Automatic Control*, Vol 19, pp.716-723, 1974.
- [16] MacGregor, J.; Jaeckle, C.; Kiparissides, C.; Koutoudi, M, 'Process monitoring and diagnosis by multiblock PLS methods,' *AIChE Journal*, Vol.40, No. 5, pp. 826-838.1994.
- [17] Shen Yin, Steven X. Ding, Ping Zhang, Adel Hagahni and Amol Naik, "Study on modifications of PLS approach for process monitoring," *Proceeding of the 18 th World congress the International federation of Automatic Control (IFC)*, pp 12389-12394.2011.
- [18] AlGhazzawi, A.; Lennox, B, "Monitoring a complex refining process using multivariate statistics," *Control Engineering Practice*, Vol.16, No.3, pp. 294-307.2008.
- [19] Svante Wold, "Exponentially weighted moving principal components analysis and projections to latent structures," *Elsevier. Chemometrics and Intelligent Laboratory.* Vol.23, pp.149-161.1994.
- [20] Ku, W.; Storer, R.; Georgakis, C, "Disturbance detection and isolation by dynamic principal component analysis," *Chemometrics and intelligent Laboratory*, vol.301, pp.179-196.1995.
- [21] Bakshi, B.; Utojo, U, "A common framework for the unification of neural," *Chemometric and statistical modeling methods. Analytica chimica Acta*, Vol.384, No.3, pp.227-247.1999.

Références bibliographiques

- [22] D. Wang, J.A. Romagnoli, "Robust multi-scale principal components analysis with applications to process monitoring," *Journal of process control*, Vol.15, pp.869-882, 2005.
- [23] Manish Misra, H. Henry Yue, S. Joe Qin, Cheng Ling, "Multivariate process monitoring and diagnosis by multi-scale PCA," *Elsevier, Computers and Chemical Engineering*, Vol .26, pp.1281-1293, 2002.
- [24] Rongfu Luo, Manish Misra and David M. Himmelblau, "Sensor fault detection via multiscale analysis and dynamic PCA," *Ind Eng Chem Res*, Vol.38, pp.1489-1495, 1999.
- [25] Westerhuis JA, Kourti T, MacGregor JF, "Analysis of multiblock and hierarchical PCA and PLS models," *J. Chemometrics* Vol.12, pp. 301–321, 1998.
- [26] S. Qin, S. Valle, and M. Piovoso, "On unifying multi-block analysis with applications to decentralized process monitoring," *J. Chemometrics*, Vol. 15, pp. 715–742, 2001.
- [27] Gregory A. Cherry and Joe Qin, "Multiblock Principal Component Analysis Based on a Combined Index for semiconductor fault detection and diagnosis," *IEEE Transactions On Semiconductor Manufacturing*, Vol. 19. No.02, pp. 159–172, 2006.
- [28] Tan, S, & mavrovouniotis, M, L, "Reducing data dimensionality through optimising neural network inputs," *AIChE Journal*, Vol.41. No.06, pp. 1471–1480, 1995.
- [29] Qin S J, Dunia R, "Determining the number of principal components for best reconstruction," *Journal process control*, vol.10. No.02/03, pp. 245–250, 2000.
- [30] Dunia R, Qin S J, "Subspace approach to multidimensional fault identification and reconstruction," *AIChE Journal*, Vol.44. No.08, pp. 1813–1831, 1998.
- [31] Kramer A M, "Nonlinear principal component analysis using autoassociative neural networks," *AIChE Journal*, Vol.37. No.02, pp. 233–243, 1991.
- [32] Dang D, McAvoy T J, "Batch tracking via nonlinear principal component analysis," *AIChE Journal*, Vol.42. No.08, pp. 2199–2208, 1996.
- [33] R. Shao, F. Jio, E.B. Martin, A.J. Morris, "Wavelets and nonlinear principal components analysis for process monitoring," *Control engineering practice*, Vol.07, pp. 865–879, 1999.
- [34] Webb A.R, "An approach to nonlinear principal component analysis using radially symmetric kernel functions," *Statist Comput*, Vol.06, pp. 159–168, 1996.
- [35] B. Scholkopf, A. Smola, K. R. Muller, "Nonlinear component analysis as a kernel eigenvalue problem," *Neural Comput*, Vol.10 No.05, pp. 1299-1319, 1998.

Références bibliographiques

- [36] H.G.Hiden et al, "Nonlinear principal components analysis using genetic programming," *Comput Chem Eng*, Vol.23 No.03, pp. 413-425,1999.
- [37] A.Palazoglo et al, "An environment for wavelet based multivariate statistical process monitoring," in *11 th european symposium of computer aided process engineering (ESCAPE-11)*,Kolding. Denmark, 2001.
- [38] Chenkun Qi, Han-Xiong Li, "Nonlinear dimension reduction based neural modeling for distributed parameter processes," *Chemical Engineering Science*. Vol. 64, pp. 4164-4170.2009.
- [39] J.J Verbeek,N. Valassis, B. Krose, "A k-segments algorithm for finding principal curves," *Pattern Recognition letters*. Vol. 23, pp. 1009-1017.2002.
- [40] Balázs kégl, Adam Krzyzak, Tamas Linder and Kenneth Zeger, "Learning and design of principal curves," *IEEE Transactions on pattern analysis and machine intelligence*. Vol. 22, No.03, pp. 281-295.2000.
- [41] T. Hastie, Principal curves and surfaces, *PhD Thesis*, Stanford Univ,1984.
- [42] Webb A. R, "An approach to nonlinear principal component analysis using radially symmetric kernel functions," *Statist. comput*, Vol.6, pp. 159-168.1996.
- [43] Bharat Bhushan, and Jose A. Romagnoli, "Strategy for process monitoring based on radial basic function network and polygonal line algorithm," *Ind. Eng. Chem*, Vol.46,N:15, pp. 5131-5140.2007.
- [44] Mark Kramer, "Nonlinear principal component analysis using auto associative neural networks," *AIChE Journal*, Vol.37,N:02, pp. 233-243.1991.
- [45] D. Demers and Cottrell, "Nonlinear dimensionality reduction," *Neural Inform.Processing. Syst*, Vol.5, pp. 303-314.1989.
- [46] S Tan and M. Mavrouritis, "Reducing data dimensionality through optimizing neural network inputs," *AIChE J*, Vol.41. No.6, pp. 1471-1480.1995.
- [47] D. Dang and T MCAvoy, "Nonlinear principal component analysis based on principal curves and neural networks," *Compu and Chem. Eng*, Vol.20. No.1, pp. 65-78.1996.
- [48] T. Hastie and W. Sluetzle, "Principal curves," *J. Amer Statistic.Assoc*, Vol.84. No.406, pp. 502-516.1989.
- [49] Abd Halim S. maulud, Dawei wang and Joe A. Romagnoli, "Wavelet based nonlinear multivariate statistical process control," *Neural computa*, Vol.84. No.406, pp. 502-516.1989.

Références bibliographiques

- [50] Abd Halim S. Maulud, Dawei Wang and Joe A. Romagnoli, "A multi-scale orthogonal nonlinear strategy for multi-variate statistical process monitoring," *Journal of Process Control*, Vol.16, pp. 671-683.2006.
- [51] C.J. Chessari, G. W. Barton, P. Watson, "On the development of a neural network based orthogonal nonlinear principal component algorithm for process data analysis," *Proceedings, IEEE International conference on neural networks*,1995.
- [52] Juha Karhunen and Jyrki Joutsensalo, "Generalizations of principal component analysis, optimization problem, and neural networks," *Elsevier, neural networks*,Vol.8, pp. 549-562.1995.
- [53] Theodora Kourti, John F. MacGregor, "Process analysis, monitoring and diagnosis, using multivariate projection methods," *Chemometrics and intelligent Systems*,Vol.28, pp.3-21.1995.
- [54] N. Baydar, Q. Chen, A. Ball and U.Kruger, "Detection of incipient tooth defect in helical gears using multivariate statistics," *Mechanical systems and signal processing*, Vol.15, No.2, pp.303-321.2001.
- [55] E.B.Martin, A.J. Morris, J.Zhang, "Process performance monitoring using multivariate statistical process control," *IEE Proc-Control Theory Apply*, Vol.143, No.2, pp.132-144.1996.
- [56] Jyh Chheng Jeng, "Adaptive process monitoring using efficient recursive PCA and moving window PCA algorithms," *Journal of the Taiwan Institute of chemical Engineers*,Vol.41, pp. 475-481.2010.
- [57] Ricardo Dunia and S.JOE Qin, "Subspace Approach to multidimensional fault identification and reconstruction," *AIChE Journal*, Vol.44, No.8, pp. 1813-1831.1998.
- [58] Sang Wook Choi, In-Beum Lee, "Nonlinear dynamic monitoring based on dynamic kernel PCA," *Chemical Engineering Science*, Vol.59.pp. 5897-5908.2004.
- [59] Yvon Tharrault, Diagnostic de fonctionnement par analyse en composantes principales:Application à une station de traitement des eaux usées, *Thèse de Doctorat de l'école doctorale IAEM LORRAINE*, France.2008.
- [60] Janos Getler, Weihua Li, Yunbing Huang and Thomas McAvoy, "Isolation enhanced principal component analysis," *AIChE Journal*, Vol. 45, pp.323-334 .1999.
- [61] Salim Aouabdi, Mahmoud TAibi, Slimane Bouras et Nadir Boutasseta, "Using multi-scale entropy and principal component analysis to monitor gears degradation via the

Références bibliographiques

- motor current signature analysis,” *Mechanical Systems and Signal Processing*, Vol. 90, pp.298-316 .2017.
- [62] Salim Aouabdi, Mahmoud Taibi et Nadir Boutasseta, “Fault detection in solar photovoltaic arrays using principal component analysis and outlier detection rules,” 3 rd International conference on embedded systems in telecommunication and instrumentation, identification and control. ICESTI2016, October 24-26, ANNABA,2016.
- [63] H Henry Yue, S. Joe Qin, “Reconstruction-based fault identification using a combined index,” *Ind. Eng. Chem. Res*, Vol. 40, pp.4403-4414.2001.
- [64] Carlos Alcalá, S. Joe Qin, “Reconstruction-based Contribution for Process Monitoring,” *Proceeding of the 17th World Congress IFAC*, seoul, Korea, pp.7889-7894.2008.
- [65] M. Manimozhi, “Fault detection and diagnosis in biochemical processes,” *Int. J. Chem. Sci*, Vol. 8,No.5, pp.16-21.2010.
- [66] Reza Sharifi,Reza Langari, “Sensor fault diagnosis with a probabilistic decision process,” *Mechanical systems and signal processing*, Vol. 34, pp.146-155.2013.
- [67] Paul M.Frank, “Fault Diagnosis in dynamic systems using analytical and knowledge-based redundancy- A survey and some new results,” *Automatica*, Vol. 26,No.3, pp.459-474.1990.
- [68] Janos J. Gertler, Ramin Monajemy, “Generation directional residuals with dynamic parity relations,” *Automatica*, Vol. 31,No.4, pp.627-635 .1995.
- [69] Venkat Venkatasubramanian, Raghunathan Rengaswamy,Surya N. Kavuri, Kewen Yin, “A review of process fault detection and diagnosis Part III: Process history based methods,” *Computers and Chemical Engineering*, Vol. 27, pp.327-349 .2003.
- [70] J. Edward Jackson, GovindS. Mudholkar, “Control procedures for residuals associated with principal component analysis,” *Rechnometrics*, Vol. 21,No:3, pp.341-349 .1979.
- [71] BY G. E.P.Box, “Some theorems on quadratic forms applied in the study of analysis of variance problems, I. Effect of inequality of variance in the one-way classification,” *Annals of Mathematical Statistics*, Vol. 25, pp.290-302 .1954.
- [72] Jack Prins, Doug Mader, “Multivariate control charts for grouped and individual observations,” *Quality Engineering*, Vol. 10, N: 1, pp.49-57 .1997.
- [73] Baligh Mnassri, Analyse de données multivariées et surveillance des processus industriels par analyse en composantes principales, *Thèse de Doctorat de Aix-Marseille Université* .2012.

Références bibliographiques

- [74] Mosabber Uddin Ahmed and Danilo P. Mandic, "Multivariate multiscale entropy analysis," *IEEE signal processing letters*, Vol.19, No.2, pp.91-94.2012.
- [75] Yunbing Huang, Janos Gertler, Thomas J. McAvoy, "Sensor and actuator fault isolation by structured partial PCA with nonlinear extensions," *Journal of process control*, Vol.10, pp.459-469.2000.
- [76] Chris L. Stork, David J. Veltkamp, and Bruce R. Kowalski, "Identification of multiple sensor disturbances during process monitoring," *Anal. Chem*, Vol.69, pp.5031-5036.1997.
- [77] Jin Cao, and Janos Gertler, "Partial PCA-based optimal structured residual design for fault isolation," *Proceeding of the American control conference*, pp.4420-4425.2004.
- [78] Rainer Ansorge, "What does the entropy condition mean in traffic flow theory," *Transpn. Res.*, Vol. 24, No:2, pp.133-143 .1990.
- [79] Jin Wang, Pengjian shang, Jianan Xia, Wenbin shi, "EMD based refined composite multiscale entropy analysis of complex signals," *Physica A*, Vol. 421, pp.583-593 .2015.
- [80] Madalena costa, Ary L. Goldberger, C. K. Peng, "Multiscale entropy analysis of complex physiologic time series," *Physical review letters*, Vol. 89, No: 6, pp.68102-68105 .2002.
- [81] Hong-Bo Xie, Wei-Xing He, Hui Liu, "Measuring time series regularity using nonlinear similarity-based sample entropy," *Physics letters A*, Vol. 371, pp.7140-7146 .2008.
- [82] J. S. Richman J. R, Moorman J.R, "Physiological time-series analysis using approximate entropy and sample entropy," *Am J Physiol Heart circ Physiol*, Vol. 278,H2039.2000.
- [83] Lake DE, Richman J. R, Moorman J.R, "Sample entropy analysis of neonatal heart rate variability," *Am J Physiol Heart circ Physiol*, Vol. 283,R789.2002.
- [84] Steven M. Pincus, "Approximate entropy as a measure of system complexity," *Proc. Natl. Acad. Sci. USA*, Vol. 88, pp.2297-2301.1991.
- [85] Liang Zhao, Filter-based multiscale entropy analysis of complex physiological time series, *Thèse de Doctorat de Syracuse Université*. 2013.
- [86] Xianfeng Fan, Ming J. Zuo, "Gearbox fault detection using Hilbert and wavelet packet transform," *Mechanical systems and signal processing*, Vol.20, pp.966-982.2006.
- [87] J.L .Starck, F. Murtagh, R. Gastaud, "A new entropy measure based on the wavelet transform and noise modeling," *special issue on multirate systems, filter banks, wavelets and applications of IEEE Transactions on CASII*, Vol.45, No:8,1998.

Références bibliographiques

- [88] Jean-Luc Starck, Sandrine Pires, Alexandre Réfrégier, “Weak lensing mass reconstruction using wavelets,” *Astronomy & Astrophysics* manuscript, ph/0503373v2, pp.1-12, 2014.
- [89] Hans C. Fogedby, “On the phase space approach to complexity,” *Journal of statistical physics*, Vol.69, pp.411-425,1992.
- [90] Marcello Carlo, “Measure of 1/f noise using the sound card of a PC,” *American journal of physics*, Vol.84, pp.311-316,2016.
- [91] E. Milotti, “1/f noise: a pedagogical review,” e-print <https://arXiv.org/ftp/physics/papers/0204/0204033.pdf>.
- [92] Anne Humeau-Heurtir, “The multiscale entropy algorithm and its variants,” *A review Entropy*, Vol.17, pp.3110-3123,2015.
- [93] José Fernando Valencia, et al, “Refined Multiscale entropy: Application to 24-h Holter recordings of heart period variability in healthy and aortic stenosis subjects,” *IEEE Transactions on biomedical engineering*, Vol.56, No.9,pp.2202-2213,2009.
- [94] Stéphane Jaffard, Yves Meyer, Robert D. Ryan, *Wavelets, Books, Tool for science & technology*, SIAM,2001.
- [95] Jikai Chen and Guoqing Li, “Tsallis wavelet entropy and its application in power signal analysis,” *Entropy 2014*, Vol.16, pp.3009-3025,2009.
- [96] Francois Maillot, “ Une construction d'ondelettes de Daubechies,” <http://www.normalesup.org/~maillot/TIPE.pdf>,2006.
- [97] En-Bing Lin and Mojisola Oyapero, “Wavelet variance and entropy of DNA Sequences,” *International journal of computer and communication engineering*, Vol.1, No:1,pp.70_72,2012.
- [98] Can He, Jianchun Xing, Juelong Li, Wei Qian and Xun Zhang, “ Anew structural damage identification method based on wavelet packet energy entropy of impulse response,” *The open civil engineering journal*, Vol.9, ,pp.570_576,2015.
- [99] C. James Li, J. D. Limmer, “Model-based condition index for tracking gear wear and fatigue damage,” *Wear*, Vol.241, No.1, pp.26-32, 2000.
- [100] S. H. Kia, H. Henao, G. Capolino, “Gear Tooth Surface Damage Fault Detection Using Induction Machine Stator Current Space Vector Analysis,” *IEEE Transactions on Industrial Electronics*, Vol.62,No.3, pp.1866-1878, 2015.
- [101] J. Rafiee, M. A. Rafiee, and P. W. Tse, “Application of mother wavelet functions for automatic gear and bearing fault diagnosis,” *Expert Systems With Applications*, Vol. 37,

Références bibliographiques

- No. 6, pp. 4568–4579, 2010.
- [102] M. Amarnath and I. R. P. Krishna, “Detection and diagnosis of surface wear failure in a spur geared system using EEMD based vibration signal analysis,” *Tribology International*, Vol. 61, pp. 224–234, 2013.
- [103] W. Wang, “Early detection of gear tooth cracking using the resonance demodulation technique,” *Mechanical system and signal processing*, Vol. 20, No. 2, pp. 332–349, 2006.
- [104] J. Sanz, R. Perera and C. Huerta, “Gear dynamics monitoring using discrete wavelet transformation and multi-layer perceptron neural networks,” *Applied Soft Computing*, Vol. 12, pp. 2867–2878, 2012.
- [105] N. Feki, G. Clerc, and P. Vexé, “Gear and motor fault modeling and detection based on motor current analysis,” *Electric Power Systems Research*, Vol. 95, pp. 28–37, 2013.
- [106] T. H. Loutas, G. Sotiriades, I. Kalaitzoglou and V. Kostopoulos, “Condition monitoring of a single-stage gearbox with artificially induced gear cracks utilizing on-line vibration and acoustic emission measurements,” *Applied Acoustics*, Vol. 70, No. 9, pp. 1148–1159, 2009.
- [107] Mahmoud Hamel, Abdulmajid Addali and David Mba, “Investigation of the influence of oil film thickness on helical gear defect detection using Acoustic Emission,” *Applied Acoustics*, Vol. 79, pp. 42–46, 2014.
- [108] D. P. Jena, S. N. Panigrahi and Rajesh Kumar, “Gear fault identification and localization using analytic wavelet transform of vibration signal,” *Measurement*, Vol. 46, No. 3, pp. 1115–1124, 2013.
- [109] T. Y. Wu, J. C. Chen and C. C. Wang, “Characterization of gear faults in variable rotating speed using Hilbert-Huang Transform and instantaneous dimensionless frequency normalization,” *Mechanical Systems and Signal Processing*, Vol. 30, pp. 103–122, 2012.
- [110] Chinmaya Kar, A. R. Mohanty, “Multistage gearbox condition monitoring using motor current signature analysis and Kolmogorov-Smirnov test,” *Journal of sound and vibration*, Vol. 290, pp. 337–368, 2006.
- [111] N. Baydar, Q. Chen, A. Ball and U. Kruger, “Detection of incipient tooth defect in helical gears using multivariate statistics,” Vol. 15, pp. 303–321, 2001.
- [112] Qingbo He, Fanrang Kong and Ruqiang Yan, “Subspace-based gearbox condition monitoring by kernel principal component analysis,” *Mechanical Systems and Signal Processing*, Vol. 21, pp. 1755–1772, 2007.

Références bibliographiques

- [113] A. R. Mohanty and C. Kar, “Monitoring gear vibrations through motor current signature analysis and wavelet transform,” *Mechanical Systems and Signal Processing*, Vol. 20, No. 1, pp. 158–187, 2006.
- [114] S. Rajagopalan, T. G. Habetler, R. G. Harley, T. Sebastian and B. Lequesne, “Current / voltage based detection of faults in gears coupled to electric motors,” *IEEE Trans. Industry Application*, Vol. 42, No. 6, pp. 1412–1420, 2006.
- [115] J. R. Ottewill and M. Orkisz, “Condition monitoring of gearboxes using synchronously averaged electric motor signals,” *Mechanical Systems and Signal Processing*, Vol. 38, No. 2, pp. 482–498, 2013.
- [116] S. H. Kia, H. Henao, G. Capolino, “A Modeling Approach for Gearbox Monitoring Using Stator Current Signature in Induction Machines,” *IEEE*, 978-1-4244-2279-1, 2008.
- [117] N. Feki, G. Clerc, and P. Velez, “An integrated electro-mechanical model of motor-gear units — Applications to tooth fault detection by electric measurements,” *Mechanical Systems and Signal Processing*, Vol. 29, pp. 377–390, 2012.
- [118] J. R. Ottewill, M. Orkisz, “Condition monitoring of gearboxes using synchronously averaged electric motor signals,” *Mechanical Systems and Signal Processing*, Vol. 38, pp. 482–498, 2013.
- [119] R. Obaid, T. Hableter, “Effect of load on detecting mechanical faults in small induction motors,” *Proceedings of symposium on diagnostics for electric machines, power electronics and drives, SDEMPED, Atlanta*, pp. 307–311, 2003.
- [120] L. Zhang, G. Xiong, H. Liu, H. Zou, and W. Guo, “Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference,” *Expert Systems With Applications*, Vol. 37, No. 8, pp. 6077–6085, 2010.
- [121] J. D. Jiang, J. Chen and L. S. Qu, “The application of correlation dimension in gearbox condition monitoring,” *Journal of sound and vibration*, vol. 223, no.4, pp. 529–541, 1999.
- [122] F. A. Andrade, I. Esat and M. N. Badi, “A new approach to time domain vibration condition monitoring: gear tooth fatigue crack detection and identification by the Kolmogorov-Smirnov test,” *Journal of sound and vibration*, Vol. 240, No.5, pp. 909–919, 2001.
- [123] K. Zhu, X. Song, and D. Xue, “A roller bearing fault diagnosis method based on hierarchical entropy and support vector machine with particle swarm optimization algorithm,” *Measurement*, Vol. 47, pp. 669–675, Jan. 2014.

Références bibliographiques

- [124] M.Costa,A.L. Goldberger,C.K.Peng, “Multi-scale entropy analysis of phsiologic time series,”*Physical Review Letters*, 89.062102.2002.
- [125] Shahin Hedayati kia, Humberto Henao and Gérard-André Capolino, “Analytical and experimental study of gearbox mechanical effect on the induction machine stator current signature,”*IEEE Transactions industry application*, Vol.45, NO:4,PP.1405-1415.2009.
- [126] Martin Blodt, Marie Chabert, Jérémie Regnier, Jean Faucher, “Mechanical load fault detection in induction motors by stator current time frequency analysis,” *IEEE Transactions Industry applications*, Vol.42, NO: 6, pp.1454-1463.2006.
- [127] Carlos. Verucchi. J. Bossio, G. Bossio and G. Acosta, “Misalignment detection in induction motors with flexible coupling by means of estimated torque analysis and MCSA,” *Mechanical Systems and Signal Processing*, Vol. 80, pp. 570–581, 2016.