



UNIVERSITE M'HAMED BOUGARA-BOUMERDES

Faculté des Hydrocarbures et de la Chimie

Laboratoire d'Automatique Appliquée

THÈSE DE DOCTORAT

Présentée par

BAICHE KARIM

Filière : Génie électrique

Option : Automatique Appliquée et traitement de signal

Surveillance Automatisée

de

Processus Industriels Complexes

Soutenue publiquement le **01/07/2014**, devant le Jury composé de :

KIDOUCHE Madjid	Professeur	Université de Boumerdès	Président
ZELMAT Mimoun	Professeur	Université de Boumerdès	Rapporteur
LACHOURI Abderazek	MCA	Université de Skikda	Examineur
KHOHEMANE Lakhdar	MCA	Université de Skikda	Examineur

Résumé

Les processus industriels complexes nécessitent une méthodologie de détection rapide et précoce des défaillances dans leurs systèmes et machines à cause de l'utilisation fréquente de ces derniers dans diverses applications et domaines ainsi que leur impact socio-économique. Le travail présenté dans cette thèse évoque plusieurs approches de traitement et d'analyse appliquées au diagnostic des défauts à savoir certains défauts de machines tournantes (roulement) et défauts de capteurs (système à trois réservoirs –three tank system).

Pour mettre en œuvre ce travail de recherche, nous avons établi une feuille de route selon les démarches suivantes :

- Etablir un état de l'art sur le principe du FDI et les différents défauts pouvant être enregistrés et identifiés.
- Etablir un prétraitement basé sur l'analyse spectrale avec modèle et sans modèle en utilisant les statistiques d'ordre deux et d'ordre supérieur.
 - ✓ le premier type d'approche consiste à utiliser des modèles analytiques du processus, ceux-ci fournissent une estimation en ligne des grandeurs non mesurables.
 - ✓ la seconde catégorie d'approche consiste à analyser les signaux mesurés sur la machine en cours de fonctionnement. Les analyses sont réalisées pour la plupart, dans le domaine fréquentiel et en régime permanent. Les informations issues de ces analyses permettent souvent une identification efficace de défaillances présentes au niveau des différents organes du processus. Toutefois ces approches fréquentielles trouvent leurs limites en présence d'importants bruits de mesure qui noient l'information pertinente.
- Etablir un test statistique basé sur la SPE en utilisant la MSPCA,
- Identifier les sources de défaillances en utilisant l'ACI.

Mots clé : Diagnostic, défaut, analyse haute résolution, MSPCA, Ondelette, ACI, système à trois réservoirs, machine tournante.

العمليات الصناعية المعقدة تتطلب منهجية للكشف السريع و المبكر عن الأعطاب (العيوب)

استخدامها المتكرر في مختلف التطبيقات

العمل المقدم في هذه الأطروحة يقترح تطبيق العديد من طرق تحليل

تشخيص الأعطاب (العيوب). كتطبيقات عملية على ذلك بعض عيوب

() عيوب أنظمة الالتقاط (Three tank system-).

لتنفيذ هذا البحث، قمنا بإنشاء خارطة طريق وفقاً للخطوات التالية:

• وضع فكرة عامة حول مبدأ الكشف و عزل العيوب FDI مختلف العيوب يمكن تسجيلها و تحديدها.

• القيام بمعالجة أولية تعتمد على التحليل الطيفي

الثانية و رتب أعلى.

✓ نهجية الأولى تعتمد على استخدام النماذج التحليلية، لأنها توفر تقديراً كميات غير قابل للقياس.

✓ نهجية الثانية تعتمد على تحليل الإشارات التي تم التقاطها على الجهاز أثناء التشغيل.

التحليلات أجريت، معظمها الطيفي مع

عليها من هذه التحليلات تسمح في كثير من الأحيان تحديد فعال للعيوب

. إلا أن هذه المنهجيات الطيفية تجد محدوديتها بسبب

وجود ضوضاء القياس و التي تغطي المعلومة المفيدة.

• خطأ التنبؤ التريبيعي (SPE) تحليل

الأساسي متعدد العدديّة (MSPCA)

• تحديد مصادر العيوب التحليل إلى عناصر مستقلة (ACI).

: التشخيص، الأعطاب، التحليل الترددي العالي الدقة الموجات الرقمية تحليل

الرئيسية المتعددة الحجم لتحليل لمكونات مستقلة، نظام الخزانات الثلاث، الآلات الدوارة.

SUMMARY

Complex industrial processes require a methodology for rapid and early detection of failures in their systems and machines because of the frequent use of these in various applications and fields as well as their socio-economic impact.

The work presented in this thesis suggests several approaches of processing and analysis applied to fault diagnosis as applications certain faults of rotating machines (rolling bearing) and sensor fault system (three tanks system).

To implement this research, we established a roadmap according to the following steps:

- Establish a state of the art on the principle of FDI and the various defects that can be recorded and identified.
- Establish a pretreatment based on spectral analysis with model and without model using statistics order two and higher.
 - ✓ The first type of approach is to use analytical models of the process; they provide online estimate of unmeasurable quantities.
 - ✓ Second type of approach is to analyze the measured signals on the machine during operation. Analyzes were performed for the most part in the frequency domain and in the steady state. The information from these analyzes often allow efficient identification of faults present in the different organs of the process. However, these frequency approaches are limited in the presence of significant measurement noise that drowned the relevant information.
- Establish a statistical test based on the SPE (Squared Prediction Error) using the MSPCA (Multi-Scale Principal Component Analysis),
- Identify sources of failures using the ICA (Independent Component Analysis).

Keywords: Diagnosis, fault, high resolution analysis, MSPCA, Wavelet, ACI, three tank system, rotating machine.

Liste des figures

Figure 1.1	Localisation des défauts selon la littérature.	10
Figure 1.2	Structure générale d'une procédure de diagnostic.	11
Figure 1.3	Étapes du diagnostic à base de modèles.	17
Figure 2.2	Estimateur du spectre DSP.	23
Figure 2.3	Structure en treillis d'un filtre transversal.	36
Figure 2.4	Structure en treillis d'un filtre en RII.	36
Figure 3.1	Ondelette de Morlet.	49
Figure 3.2	Ondelette Gaussian Chirp (k=1).	49
Figure 3.3	Ondelette de chapeau Mexicain	51
Figure 3.4	Ondelette de Haar	49
Figure 3.5	Analyse et synthèse dans la transformée orthogonale en ondelettes.	54
Figure 3.6	Organigramme de Traitement	55
Figure 3.7	ACP Multi-échelle :	64
Figure 4.1	Principes du modèle ACI	71
Figure 4.2	Diagramme de diagnostic et isolation de défauts utilisant les BSSFs et l'analyse statistique	77
Figure 4.3	Spectre des composantes indépendantes du défaut sur la cage interne du roulement après application de la EMD.	80
Figure 5.1	Roulement à billes	86
Figure 5.2	Différents composants d'un roulement	84
Figure 5.3	Banc d'essai de machine tournante.	84
Figure 5.4	Signaux de vibration d'un roulement neuf.	87
Figure 5.5	Signaux de vibration d'un roulement avec un défaut inner rice	87
Figure 5.6	Signaux de vibration d'un roulement avec un défaut outer rice	88
Figure 5.7	Signaux de vibration d'un roulement avec un défaut de ball	88
Figure 5.8	Coefficients de détail (niveau 5) d'un roulement neuf du capteur #01	89
Figure 5.9	Coefficients de détail (niveau 5) d'un roulement neuf du capteur #02.	89
Figure 5.10	Coefficients de détail (niveau 5) d'un roulement neuf du capteur #03	90
Figure 5.11	Coefficients de détail (niveau 5) d'un roulement neuf du capteur #04	90
Figure 5.12	Coefficients de détail (niveau 5) avec un défaut inner rice du capteur #01	91
Figure 5.13	Coefficients de détail (niveau 5) avec un défaut inner rice du Capteur #02	91
Figure 5.14	Coefficients de détail (niveau 5) avec un défaut inner rice du Capteur #03	92
Figure 5.15	Coefficients de détail (niveau 5) avec un défaut inner rice du Capteur #04	92
Figure 5.16	Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #01	93
Figure 5.17	Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #02	93
Figure 5.18	Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #03	94
Figure 5.19	Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #04	94
Figure 5.20	Coefficients de détail (niveau 5) avec un défaut Ball du Capteur #02.	95
Figure 5.21	Coefficients de détail (niveau 5) avec un défaut Ball du Capteur #02.	95
Figure 5.22	Coefficients de détail (niveau 5) avec un défaut Ball du Capteur #03.	96

Figure 5.23 Coefficients de Détail (niveau 5) avec un défaut Ball du Capteur #04.....	96
Figure 5.24 Evolution du SPE (D1).....	100
Figure 5.25 Evolution des Valeurs Propres (D1).....	97
Figure 5.26 Evolution du SPE (D2).....	100
Figure 5.27 Evolution des Valeurs Propres (D2).....	97
Figure 5.28 Evolution du SPE (D3).....	101
Figure 5.29 Evolution des Valeurs Propres (D3).....	98
Figure 5.30 Evolution du SPE (D4).....	101
Figure 5.31 Evolution des Valeurs Propres (D4).....	98
Figure 5.32 Evolution du SPE (D5).....	102
Figure 5.33 Evolution des Valeurs Propres (D5).....	99
Figure 5.34 Evolution du SPE (D1)	102
Figure 5.35 Evolution des Valeurs Propres (D1).....	99
Figure 5.36 Evolution du SPE (D2).....	103
Figure 5.37 Evolution des Valeurs Propres (D2)	100
Figure 5.38 Evolution du SPE (D3).....	103
Figure 5.39 Evolution des Valeurs Propres (D3)	100
Figure 5.40 Evolution du SPE (D4).....	104
Figure 5.41 Evolution des Valeurs Propres (D4).....	101
Figure 5.42 Evolution du SPE (D5).....	104
Figure 5.43 Evolution des Valeurs Propres (D5)	101
Figure 5.44 Station DTS-200 (three tank system).....	103
Figure 5.45 Système à trois réservoirs (three tank system)	104
Figure 5.46 Norme euclidienne en pourcentage pour chaque matrice de séparation correspondant à chaque IC.....	105
Figure 5.47 Les composantes indépendantes des filtres BSS en mode normal (sain).....	107
Figure 5.48 Les composantes indépendantes des filtres BSS dans le cas 1.	108
Figure 5.49 Les composantes indépendantes des filtres BSS dans le cas 2.	109
Figure 5.50 Les composantes indépendantes des filtres BSS dans le cas 3.	110

Liste des tableaux

Table 5.1 Géométrie du roulement (en mm).....	85
Table 5.2 Les fréquences de défaut (multiple de la vitesse de rotation en Hz)	85
Table 5.3 Performances de reconstruction de modèles par BSS	105
Table 5.4 Les composants de la dissymétrie des BSSF des variables du système expérimental dans l'état normal.	107
Table 5.5 Les composants de la dissymétrie des BSSF des variables du système expérimental avec défaut, cas 1.	108
Table 5.6 Les composants de la dissymétrie des BSSF des variables du système expérimental avec défaut, cas 2.	109
Table 5.7 Les composants de la dissymétrie des BSSF des variables du système expérimental avec défaut, cas 3.	110

Sommaire

LISTE DES FIGURES

LISTE DES TABLEAUX

INTRODUCTION GÉNÉRALE.....	1
1. CHAPITRE 1 : ETAT DE L'ART SUR LE DIAGNOSTIC DANS LES SYSTÈMES DYNAMIQUES	4
1.1 Introduction	4
1.2 Notions de défaut, dysfonctionnement et panne	4
1.3 Les concepts fondamentaux du diagnostic.....	10
1.4 Les méthodologies de diagnostic	15
1.4.1 Les méthodes de diagnostic à base de modèles.....	16
1.4.2 Les méthodes de diagnostic à base de données "Modèles boîte noire"	19
1.5 Conclusion	19
1.6 Références bibliographiques	20
2. CHAPITRE 2 : ANALYSE SPECTRALE HAUTE RÉOLUTION	22
2.1 Problématique de l'Analyse spectrale	22
2.2 Méthodes non paramétriques	22
2.3 Méthodes Autorégressives	29
2.4 Méthode de la prédiction linéaire	34
2.5 Estimation en treillis pour la réalisation stochastique	35
2.6 Analyse Spectrale Haute Résolution.....	37
2.7 Méthode de Prony	37
2.8 Méthode de Pisarenko.....	39
2.9 Conclusion	42
2.10 Références bibliographiques	42
3. CHAPITRE 3 : LES RÉSEAUX D'ONDELETTES ET L'ANALYSE EN COMPOSANTS PRINCIPALES (ACP).....	44
3.1 Introduction.....	44
3.2 Les Ondelettes dans le cas Continu	45
3.3 Les Ondelettes dans le cas discret.....	47
3.4 Quelques exemples d'ondelettes	48

3.5 Analyse Multirésolution	49
3.3.1 Définition	50
3.3.2 Fonction d'échelle	52
3.6 Ondelettes et filtrage numérique	52
3.7 Algorithme de reconstruction	54
3.8 Reconnaissance et Classification	54
3.8.1 Théorème de Parseval (Evaluation de la déviation d'énergie)	55
3.8.2 Réseaux Neuronaux Probabilistes (PNN)	56
3.9 Analyse en Composantes Principales (ACP)	56
3.9.1 Introduction	56
3.9.2 Principe de l'Analyse en Composantes Principales	57
3.9.3 Détection des défauts	61
3.9.4 Formulation MSPCA	64
3.10 Conclusion	65
3.11 Références bibliographiques	65
4. CHAPITRE 4 : L'ANALYSE EN COMPOSANTE INDÉPENDANTE (SÉPARATION AVEUGLE DES SOURCES)	68
4.1 Introduction	68
4.2 Séparation aveugle de sources (Blind source separation BSS)	69
4.3 Analyse en composantes indépendantes (ICA)	70
4.4 L'algorithme de maximisation de l'information	72
4.4 Méthodologie proposée	74
4.4.1 Les filtres de séparation aveugle de source	75
4.4.2 L'analyse statistique	77
4.5 Domaines d'application de l'ACI	78
4.6 Conclusion	80
4.7 Références bibliographiques	81
5. CHAPITRE 5 : APPLICATIONS AUX SYSTÈMES PHYSIQUES	83
5.1 Application 1 : Diagnostic de l'endommagement de roulement de machine tournante .	83
5.1.1 Introduction	83
5.1.2 Description du défaut	83
5.1.3 Présentation du banc d'essai	84
5.1.4 Résultats expérimentaux et discussion	86
5.1.5 Conclusion	102

5.2 Application 2 : Banc d'essai « Système à trois réservoirs »	103
5.2.1 Introduction	103
5.2.2 Présentation du Banc d'essai	103
5.2.3 Résultats expérimentaux et discussion	104
5.2.4 Conclusion	111
5.3 Références bibliographiques	112
CONCLUSION GÉNÉRALE	113

Introduction générale

Le diagnostic précoce d'anomalies, dans tous les domaines, était depuis longtemps le rêve de l'être humain. Ce rêve ne cesse de devenir une réalité.

Dans les systèmes industriels actuels l'automatisation a pris une part de plus en plus importante dans leur réalisation. Cela s'explique par la complexification des systèmes (augmentation du nombre de composants et de leurs interactions) afin de réaliser des fonctions de plus en plus complexes, et d'autre part par les besoins économiques actuels que sont la réduction des coûts de maintenance ainsi que l'amélioration des performances de fonctionnement, de fiabilité et de sécurité des systèmes.

Les systèmes industriels sont des combinaisons complexes et structurés de multiples composants mécaniques, électroniques et informatiques en interaction permanente et combinant de multiples phénomènes physiques. La complexification de ces systèmes a comme conséquences un accroissement des défauts potentiels (défaillances) pouvant apparaître dans le système. Une défaillance peut mettre le système dans un état anormal de fonctionnement (hors conditions opérationnels). Cette situation a un impact néfaste sur le système ainsi que sur son environnement : pertes de performances, casse de composants, dégradation de l'environnement, pertes de vies humaines et dans tous les cas un impact financier. Il est alors important de prendre en compte cette problématique (occurrences de défauts potentiels) dans le système afin d'éviter toutes conséquences dommageables.

La solution appropriée, permettant de répondre à cette problématique, est le développement d'outils de surveillance en ligne du système basés sur le diagnostic de défauts. L'objectif du diagnostic de défauts est de détecter et de localiser, le plus précisément possible, les défauts pouvant apparaître dans un système ; ceci dans le but de prendre les décisions adéquates quant aux poursuites de fonctionnement appropriées suivant la sévérité du défaut diagnostiqué : poursuite en fonctionnement normal pour des défauts n'impactant que les performances du système, ou poursuite en mode dégradé, voire mise à l'arrêt du système, pour des défauts ayant de plus graves conséquences. Le dispositif doit être capable de déterminer le plus précisément possible quelles sont les parties en défaut du système et de quels types de dysfonctionnements elles souffrent.

Le diagnostic a un rôle prépondérant. En effet, en accomplissant une

surveillance du système, le diagnostic permet une détection et une identification des défauts de manière précise et rapide. Il est ainsi possible de n'intervenir qu'en présence de composants défectueux, de minimiser le temps de réparation, et de fournir une réponse fiable et facilement interprétable malgré la complexité des systèmes.

Le diagnostic automatique est une discipline relativement ancienne dont les premiers travaux sont apparus dès les années 1970, en même temps que l'intégration des premiers calculateurs numériques permettant le contrôle automatique des systèmes. Depuis, et bien que de nombreuses méthodologies furent développées par différentes communautés issues de domaines de recherche variés, peu de théories générales existent et beaucoup d'approches sont plus ad-hoc sans démarche systématique ni générique.

Malgré l'abondance des travaux traitant du diagnostic, la représentation des défauts reste assez marginale et incomplète. Il y a en particulier difficulté à prendre en compte la diversité des défauts. Pour cette raison la majorité des travaux essaye d'étudier un cas bien spécifique de défaut et d'en extraire ses caractéristiques dans un objectif de réaliser une relation directe entre défaut et réponse.

Chaque communauté de chercheurs cherche à exploiter les techniques qu'elle en dispose ou de développer d'autres pour assurer cette relation (défaut-réponse). Certains utilisent les méthodes à base de modèles et d'autres non. Malheureusement les méthodes à base de modèles deviennent de plus en plus complexes vu la complexité des systèmes industriels et le caractère fortement non linéarité de la plus part d'entre eux.

Pour cette raison, l'autre communauté cherchent à exploiter les données observables du système et d'en faire une comparaison entre les données observables dans l'état normal et celles dans le cas d'occurrence de défaut.

Dans notre travail actuel, nous nous sommes intéressés à deux défauts très répondus, à savoir les défauts de roulements à billes (qui occupes une place très importantes dans les machines tournantes) et les défauts de capteurs qui sont très répondus aussi.

Pour le premier défaut, l'analyse spectrale occupe une place de marque, de ce fait nous avons continu le travail mais en appliquant l'analyse en composantes principales (ACP) et les réseaux d'ondelettes pour séparer entre les différents défauts présents.

Quant au deuxième défaut, nous avons appliqué l'analyse en composante indépendante qui apparue plus adaptée à ce type de défauts.

Cette thèse est organisée comme suit : une introduction générale suivie de cinq chapitres.

Le premier chapitre va donc présenter un état de l'art du diagnostic. Nous commençons par donner des définitions puis un état de l'art des différentes caractéristiques d'un défaut pour conclure qu'un défaut peut être caractérisé par son comportement et son effet sur le système. Après nous ferons un balayage sur les concepts fondamentaux du diagnostic en présentant les exigences liées à ce dernier et nous terminerons par une présentation des différentes méthodologies de diagnostic issues de la littérature.

Le deuxième, troisième et quatrième chapitre sont réservés aux développements mathématiques de techniques bien choisies pour être appliquées au diagnostic de cas réels. Ces techniques sont : l'analyse spectrale haute résolution à savoir la méthode de Prony et Pisarenko, qui est lui y réservée le chapitre 2. Le chapitre 3 traite les réseaux d'ondelette en se basant sur les coefficients de détails et d'approximation ainsi que l'analyse en composantes principales. Quant à l'analyse en composante indépendante et vu sa nouveauté de son application dans le domaine du diagnostic, nous lui avons réservé le chapitre 4. Dans ce chapitre, après une introduction et présentation du principe de la technique, nous avons développé les filtres de séparation aveugle de sources BSSF (Blind Source Separation Filter) et à la fin une présentation de certaines applications où l'utilisation de l'ACI a donné ses fruits.

Le dernier chapitre (5), présente deux applications type du diagnostic : le diagnostic des défauts de roulements à billes dans une machine tournante (où un banc d'essai est présenté) en utilisant les variations dans le signal vibratoire. Trois défauts sont introduits volontairement, à savoir une rayure sur la bague interne, une rayure sur la bague externe et une autre sur la balle. Ce type de défauts présente le cas des défauts des composants du système. La deuxième application présente, met le point sur le défaut des capteurs. Ce dernier est appliqué sur le banc d'essai d'un système à trois réservoirs (three tank system) où des défauts sont causés volontairement, sur les capteurs de débits et de niveaux. Les résultats des deux applications sont présentés et discutés.

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

1. Chapitre 1 : Etat de l'Art sur le diagnostic dans les systèmes dynamiques

1.1 Introduction

L'objectif du diagnostic est la détection et l'identification des défauts d'un système à partir de l'étude de leurs effets occasionnés [1]. Le diagnostic s'inscrit dans les solutions de surveillance des systèmes dans le but de prendre les décisions adéquates quant à leurs poursuites de fonctionnement suite à des défauts apparus et diagnostiqués ; ces décisions adéquates pouvant aller de la poursuite en fonctionnement normal ou de la mise en mode dégradé, si seules les performances du système sont impactées, à la mise à l'arrêt du système si sa sécurité ou celle de son environnement sont impactées. C'est la politique de la maintenance prédictive ou conditionnelle.

Le diagnostic dans les systèmes dynamiques, a été un sujet important de recherche dès les débuts de l'Automatique moderne basée sur le calcul numérique. Ainsi de nombreuses approches ont été développées [2]. Les différentes approches du diagnostic des systèmes dynamiques semblent être souvent le résultat de contextes différents notamment en ce qui concerne les applications visées et le cahier des charges qui en résulte. Ainsi, la nature des informations disponibles sur le système ou le type de défauts à détecter conduisent à la mise en œuvre de stratégies spécifiques. Par exemple, si seules des données entrée/sortie sont disponibles sur le système, une méthode par apprentissage semblera naturellement adaptée, par contre si un modèle mathématique est disponible, les méthodes analytiques pourront être privilégiées.

Une stratégie de diagnostic doit apporter des réponses aux questions suivantes en ce qui concerne ses objectifs, ses principes de mises en œuvre et ses critères d'évaluation:

- Objectifs : que veut-on surveiller ? Quels types de défauts doit-on détecter ?
- Principes : Quel est le principe de diagnostic à mettre en œuvre ?
- Critères : quelles sont les performances attendues ? Quels sont les indices d'évaluation de ces performances ?

1.2 Notions de défaut, dysfonctionnement et panne

1.2.1 Définitions

Il existe très peu de documents s'attachent à définir formellement les notions de

défaut, dysfonctionnement et panne. Un effort de définition est accompli dans [3] pour tenter de définir ces notions de manière standard. Nous donnons ici ces notions.

Définition 1 *Un défaut (ou faute ou défaillance) est une dérive non-permise d'au moins une propriété caractéristique du système par rapport aux conditions standard et acceptables de fonctionnement du système.*

Un défaut est un état anormal de fonctionnement du système pouvant causer une réduction, voire une perte de la capacité de l'unité fonctionnelle à exécuter sa fonction requise. Un défaut est indépendant du fait que le système soit opérationnel ou non et peut très bien ne pas affecter le fonctionnement normal du système. Un défaut peut initier un dysfonctionnement ou une panne du système.

Définition 2 *Un dysfonctionnement est une irrégularité intermittente dans la réalisation d'une fonction désirée du système.*

Un dysfonctionnement est donc une interruption temporaire de la fonction du système. Il s'agit d'un évènement résultant d'un ou plusieurs défauts.

Définition 3 *Une panne est une interruption permanente de la capacité du système à exécuter une fonction requise sous des conditions opérationnelles spécifiées.*

Comme pour un dysfonctionnement, une panne est un évènement résultant d'un ou plusieurs défauts. Différents types de pannes peuvent être distingués suivant leurs nombres (panne simple ou pannes multiples) et leurs prévisions (panne aléatoire donc non prévisible, panne déterministe donc prévisible sous certaines conditions, panne systématique ou causale dépendant de conditions connues).

1.2.2 Caractéristiques des défauts

Une typologie des défauts consiste à définir un certain nombre de traits caractéristiques des défauts afin d'en faciliter la classification et l'étude. Cette partie va d'abord introduire différentes caractéristiques de défauts issues de la littérature, puis résumer ces caractéristiques afin d'obtenir une définition complète et correcte d'un défaut.

De nombreuses classifications de défauts peuvent être trouvées dans la littérature. Nous avons néanmoins observé [4] que toutes font une distinction entre le comportement du défaut, sa localisation et son effet sur le système. Ceci amène donc

naturellement à distinguer les défauts non seulement en fonction de leurs localisations et effets sur le système, mais aussi en fonction de leurs comportements.

1.2.2.1 La localisation des défauts

La partie opérante d'un système piloté est un ensemble de composants interagissant entre eux afin d'accomplir une fonction requise. Il est donc naturel de penser qu'un défaut puisse affecter soit un composant du système, soit un ensemble de composants.

1.2.3.1.1 Localisation classique selon la littérature

Selon [5], trois localisations de défauts peuvent être définies sur un système : les défauts f_i d'actionneurs, les défauts f_o de capteurs et les défauts f de composants ou du processus. En considérant les sorties observables y d'un système S d'état x , paramétré par θ et ayant les entrées u , qui s'écrit en négligeant la dynamique par l'équation 3.1 suivante :

$$y = S(x, \theta, u) \quad (3.1)$$

alors un défaut f_i perturbe la variable u des entrées du système, un défaut f_o perturbe la variable y des sorties du système et un défaut f perturbe les paramètres du système.

Selon [3], un défaut peut être localisé dans les différents types de composants du système :

- Dans un capteur, le défaut se caractérise par un écart entre la valeur réelle de la grandeur et sa mesure. Ce défaut se classe en fonction de son type : biais, dérive, modification du gain de mesure, valeurs aberrantes, blocage du capteur à une valeur atteinte ou à une coupure électrique du capteur.
- Dans le processus physique, le défaut est dû à des modifications de la structure (par exemple une fuite ou une rupture d'un organe) ou des paramètres du modèle (par exemple un encrassement d'un tuyau ou un bouchage partiel d'une conduite).
- Dans un actionneur, le défaut se traduit par une incohérence entre les commandes et la sortie du système (par exemple une pompe délivrant un

débit incohérent avec sa caractéristique hydraulique).

- Dans l'unité de contrôle commande, le défaut se caractérise par un écart entre la valeur réelle de la sortie du contrôleur, selon l'algorithme implémenté, et sa mesure.

Enfin, [6] caractérise trois cas de localisation de défauts sur le système :

- Les changements grossiers de paramètres du modèle : dans toute modélisation, il existe des processus se produisant en dessous du niveau de détails du modèle ; ces processus non-modélisés sont typiquement rassemblés comme paramètres. Les défauts de paramètres surviennent quand il y a une perturbation de l'environnement entrant dans le processus, à travers une ou plusieurs variables. Par exemple, le changement du coefficient de transfert de chaleur dû à l'encrassement dans un échangeur thermique.
- Les changements structurels : en référence aux changements dans le processus lui-même, ils se produisent à cause de graves pannes dans le système et résultent de changements dans le flot d'informations entre les différentes variables. Par exemple, les pannes de contrôleur, les blocages de valves ou encore les fuites dans les tuyauteries.
- Les mauvais fonctionnements de capteurs ou d'actionneurs : une panne dans un des instruments de contrôle (i.e. : un capteur ou un actionneur) peut causer une déviation des variables d'état du système au-delà des limites acceptables.

1.2.3.1.2 Localisation suivant les exigences

Les exigences d'un système décrivent ce que le système doit être et doit faire. Ces exigences peuvent être fonctionnelles : c'est-à-dire qu'elles décrivent les caractéristiques du système ou des processus que le système doit exécuter. Elles peuvent aussi être non-fonctionnelles et décrire ainsi les propriétés que le système doit avoir. Les exigences sont par conséquent définies sur tout ou partie du système.

Par ailleurs, un défaut peut aussi être vu comme la non-vérification d'une exigence du système ; ce qui fait qu'un défaut peut être localisé soit dans un des composants du système ou soit dans un ensemble de composants suivant que l'exigence est donnée sur tout ou partie du système. Par exemple, pour un système en boucle fermée, l'usure ou un état non-prévu du processus physique peut amener à ce

que le système de pilotage (au moins le module de régulation) pilote mal ce processus. Le défaut n'est donc pas seulement dû uniquement à ce système de pilotage ou au processus physique, mais à l'ensemble bouclé du système.

1.2.3 Le comportement des défauts

Les défauts peuvent être regroupés suivant des caractéristiques similaires. Toutes les ruptures ou casses de composants, par exemple, sont des défauts dont l'occurrence se fait brusquement. À l'inverse, les usures sont des défauts apparaissant progressivement.

Dans [3], les principaux comportements de défauts sont donnés suivant le type de composant concerné. Deux catégories comportementales sont établies : la formation et le comportement temporel. Comme l'indique le tableau 3.4, la caractéristique « formation » distingue les défauts systématiques des défauts aléatoires, alors que la caractéristique « comportement temporel » distingue les défauts permanents, les défauts transitoires, les défauts intermittents, les défauts de bruit et les défauts de dérive.

Type de composants				Défauts	
Logiciel	Matériel électronique	Composant électriques	Composants mécaniques		
				Systématique	Formation
				Aléatoire	
				Permanent	Comportement temporel
				Transitoire	
				Intermittent	
				Bruité	
				Dérive	

Tableau 1-1 Comportements suivant le type concerné de composants

- Un défaut systématique est un défaut dont l'occurrence est toujours au même moment. Elle peut résulter d'une usure ou du vieillissement du système, ou de la conséquence d'un fonctionnement spécifique.
- Un défaut aléatoire est un défaut dont l'occurrence se produit à n'importe quel moment, il n'y a aucune certitude sur celle-ci.
- Un défaut permanent est un défaut qui reste persistant après son occurrence.
- Un défaut transitoire ne persiste pas après son occurrence : c'est-à-dire qu'il

apparaît puis disparaît sans qu'il n'y ait nécessairement eu d'actions correctrices.

- Un défaut intermittent est un défaut qui apparaît puis disparaît puis réapparaît puis disparaît de nouveau, et ainsi de suite sans qu'il n'y ait nécessairement eu d'actions correctrices.
- Un défaut bruité est un défaut qui apparaît comme un bruit permanent sans être nécessairement très important et sans nécessairement évoluer.
- Un défaut de dérive est un défaut qui évolue de manière progressive.

1.2.4 Conclusion sur les caractéristiques des défauts

Cette partie nous a permis de faire un point sur les différentes caractéristiques des défauts pouvant apparaître dans un système. Nous avons ainsi vu qu'un défaut se définit suivant différentes caractéristiques qui déterminent autant son comportement que sa localisation ou encore ses conséquences. Il est possible de résumer cela en trois principales caractéristiques :

- le comportement du défaut,
- l'effet du défaut,
- les conséquences du défaut.

Comportement d'un défaut: Le comportement d'un défaut détermine son instant d'occurrence dans le temps, sa force d'apparition ainsi que sa durée de présence. L'instant d'occurrence d'un défaut, que nous réduirons à *occurrence* d'un défaut, peut être aléatoire, systématique ou dépendant d'un évènement interne ou externe au système. La force d'apparition d'un défaut peut être brusque ou progressive. Enfin, la durée de présence d'un défaut peut être permanente, transitoire ou intermittente.

Effet d'un défaut: L'effet d'un défaut détermine sa prise en compte dans le système. Il s'agit de déterminer sa localisation dans le système ainsi que la ou les perturbations induites.

Un défaut peut être localisé soit sur une partie bien déterminée du système, soit dans un ensemble de composants du système, ou même sur le système complet.

Comme le représente la figure 1.1, une partie bien déterminée du système est un capteur, un (ou des) composant(s) du processus physique, un actionneur, l'unité de contrôle commande ou encore un lien entre différents composants. Dans un

capteur, un défaut perturbe les sorties du système. Dans un (ou des) composant(s) du processus physique, un défaut perturbe les états et/ou les paramètres du système. Dans un actionneur, un défaut perturbe les entrées du système. Dans l'unité de contrôle commande, un défaut perturbe l'algorithme de contrôle commande du système. Enfin, dans un lien entre différents composants, un défaut perturbe les différentes données (physiques ou informatiques) transitant par ce lien.

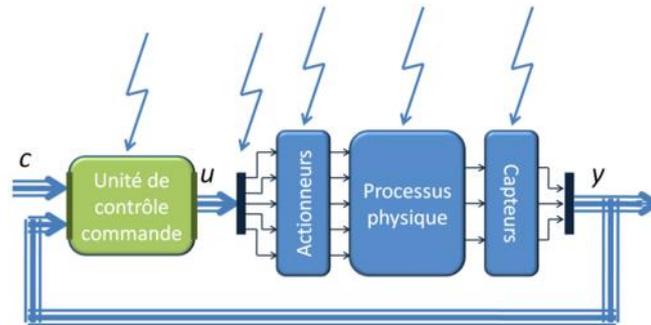


Figure 1.1 Localisation des défauts selon la littérature.

Conséquences d'un défaut: Les conséquences engendrées par un défaut, sur le système lui-même et/ou son environnement, sont à déterminer suivant les pertes potentielles (matérielles et/ou humaines) qu'il peut générer. Cette caractéristique est déterminée lors de l'étude de sûreté de fonctionnement du système.

1.3 Les concepts fondamentaux du diagnostic

1.3.1 Introduction

Comme nous l'avons signifié au début de ce chapitre, le diagnostic a pour objectif l'identification du ou des défauts probables d'un système à partir de l'étude de leurs effets occasionnés. Le cas idéal serait bien sûr, comme l'indique [7], qu'il existe une correspondance biunivoque (i.e. : une relation bijective) entre les défauts potentiels du système et les effets occasionnés par ces défauts : c'est-à-dire qu'à chaque défaut serait associée une unique liste d'effets et réciproquement qu'à chaque liste d'effets serait associé un unique défaut. Il serait ainsi facile d'obtenir le défaut apparu suite à l'étude des effets occasionnés. Cela n'est néanmoins pas le cas en pratique car plusieurs défauts distincts occasionnent généralement des effets similaires voire identiques.

Le diagnostic est donc une procédure consistant à détecter et localiser un composant

ou un élément en défaut d'un système. La détection désigne la capacité du système de diagnostic à mettre en évidence l'apparition d'un ou plusieurs défauts, et la localisation désigne la capacité à être de plus capable de préciser la nature du ou des défauts apparus. La structure générale d'une procédure de diagnostic est représentée par la figure 1.1 où le système de diagnostic est alimenté par toute la connaissance disponible sur le système : les mesures des variables et toute autre information pouvant être utile pour le diagnostic (un modèle par exemple). Ce système de diagnostic traite cette connaissance et produit un « diagnostic » qui est une liste de défauts possibles pouvant affecter le système au cours du temps. Remarquons bien que même en fonctionnement normal du système, le système de diagnostic « diagnostique » que le système fonctionne normalement.

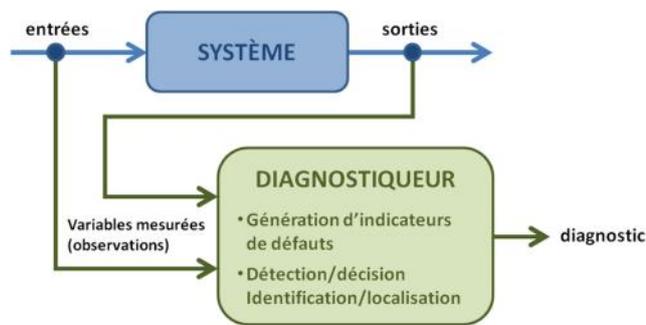


Figure 1.2 Structure générale d'une procédure de diagnostic.

Le diagnostic repose sur les deux concepts fondamentaux suivants : d'une part signaler un défaut lorsqu'il apparaît et d'autre part le localiser le plus précisément possible afin que les actions correctrices adéquates puissent être entreprises. Ces deux concepts sont généralement spécifiés comme la détection et l'isolation de défauts. La détection consiste à reconnaître un comportement anormal du système et l'isolation consiste à déterminer quel est ce comportement anormal. Remarquons cependant que cette terminologie du diagnostic n'est pas figée et qu'il est possible de trouver différentes notions résultant toutes dans le même sens final. D'une manière générale, les étapes fondamentales du diagnostic sont les suivantes:

1. détection d'un défaut : opération permettant de décider si le système est ou n'est pas en état de fonctionnement normal ; il s'agit d'une opération logique dont la réponse doit être binaire (oui ou non).
2. localisation et estimation d'un défaut : opération permettant de déterminer l'endroit du système où se trouve le défaut (i.e. : déterminer le ou les composants en défaut),

d'en déterminer sa cause ainsi que sa sévérité.

3. reconfiguration du système : opération permettant, à partir des informations fournies par les deux étapes précédentes, d'appliquer les actions correctrices au système afin soit qu'il retrouve un fonctionnement normal, soit qu'il soit mis en mode dégradé ou arrêté afin de préserver son intégrité et/ou son environnement.

La mise en place de processus permettant la réalisation de ces trois fonctions est généralement définie par l'expression tolérance aux défauts [8]. Bien que la majorité des travaux distingue clairement la troisième phase de la notion de diagnostic, certains travaux n'incluent néanmoins pas non plus la fonction de détection dans le diagnostic, [9] par exemple, celle-ci consistant donc juste à identifier les défauts détectés. Dans ce document, nous faisons le choix de considérer que le diagnostic est défini par ces deux étapes de détection et d'identification, dont nous nommerons la seconde par isolation d'un défaut.

Comme indiqué dans [9], toutes ces fonctions n'apparaissent généralement pas dans chaque application de diagnostic et ceci suivant le type de défaut à surveiller, ce que nous verrons au chapitre applications. Cette liste d'étapes n'est par ailleurs pas complète dans le sens où il est nécessaire de rajouter en amont l'acquisition des données. Cette étape consiste, en partant des signaux électriques analogiques ou numériques, à les conditionner et les prétraiter (extraction, amplification, atténuation, filtre, etc.).

1.3.2 Les exigences liées au diagnostic

Nous allons répertorier un ensemble d'exigences bien établies dans les travaux de diagnostic (voir par exemple [6]) et importantes à prendre en compte lors de la conception et le développement d'un système de diagnostic. Remarquons cependant que ces exigences, à la base élaborées pour permettre la comparaison entre les différentes méthodologies de diagnostic, ne satisferont généralement pas toutes ces exigences inventoriées.

Par ailleurs, il est important de comprendre qu'un système de diagnostic est au préalable basé sur une connaissance des défauts potentiels à prendre en compte. Quelle que soit la méthodologie de diagnostic adoptée, il est avant tout important de répertorier les défauts à traiter. Ces défauts pouvant être divers et variés, autant leurs formes que leurs apparitions ou leurs localisations, il est donc important de pouvoir déterminer leurs caractéristiques principales suivant la méthodologie choisie, et donc suivant l'algorithme de traitement utilisé par la méthodologie. Comme indiqué par [6], remarquons néanmoins un compromis entre la complétude et la finesse de caractérisation de cet ensemble de défauts

hypothétiques répertoriés : c'est-à-dire le compromis entre le fait que cet ensemble soit d'une part complet (i.e. : permettant de diagnostiquer sans ambiguïté tout comportement anormal) et qu'il soit d'autre part « fin » dans la représentation des différents défauts (i.e. : dans leurs caractérisations). Suivant la méthodologie choisie ainsi que l'implantation du système de diagnostic, les capacités de stockage et de calcul pourront être plus ou moins limitées. La définition d'un ensemble complet de défauts potentiels se fera nécessairement au détriment de la résolution de cet ensemble.

1.1.3.1 Exigences fonctionnelles

Les exigences fonctionnelles d'un système de diagnostic doivent rendre compte de son fonctionnement attendu sans prendre nécessairement en compte les solutions techniques.

Rapidité du diagnostic: Suite à l'occurrence d'un défaut, le temps nécessaire à sa détection et son isolation doit être rapide. Le système de diagnostic doit donc rapidement fournir un résultat afin de prendre les décisions adéquates avant l'apparition d'effets néfastes sur le système et/ou son environnement. Cette rapidité doit, bien entendu, être mise en relation avec la sévérité du défaut et la dynamique de ses conséquences. Remarquons néanmoins que cette performance de rapidité de diagnostic peut impacter le maintien des performances du système. En effet, un système de diagnostic conçu dans le but d'être rapide sera très certainement sensible aux bruits ou perturbations furtives (courtes et temporaires), ce qui impliquera une augmentation potentielle des fausses alarmes en fonctionnement normal et impactera ainsi les performances du système.

Discernement entre les défauts: Le système de diagnostic doit être capable de faire la différence entre plusieurs défauts. Il s'agit donc de la fiabilité de la partie isolation du diagnostic. Notons que dans le cas idéal d'absence de bruit et d'incertitudes de modélisation, cela signifie que la réponse du système de diagnostic à un défaut est « orthogonale » aux défauts qui ne sont pas apparus. Cette exigence nécessite cependant une grande précision dans la définition des caractéristiques des défauts (lors de la phase de conception) et entraîne par conséquent une fragilité face aux incertitudes de modélisation du système et des défauts.

Identification de défauts multiples: Il s'agit de la capacité du système de diagnostic à identifier plusieurs défauts survenus simultanément ou dans une fenêtre temporelle très courte. La difficulté de cette « simultanéité » provient d'une part de l'interaction

entre les conséquences des différents défauts apparus, et d'autre part de l'important volume de calcul nécessaire à une détection multiple.

Identification de nouveaux défauts: Un atout supplémentaire pour un système de diagnostic est sa capacité d'identifier de nouveaux défauts non-préalablement répertoriés. Cela signifie qu'à l'apparition d'un défaut non-répertorié, le système de diagnostic doit être capable d'une part de le détecter (i.e. : de reconnaître que le fonctionnement du système est anormal), et d'autre part de l'isoler comme étant un défaut inconnu. Le fait de reconnaître le fonctionnement du système comme étant anormal est généralement assez simple à obtenir. Par contre pour un fonctionnement anormal, décider que le défaut est connu ou inconnu est plus délicat car l'ensemble des données nécessaires à cette décision n'est généralement pas complet : les variables nécessaires à l'observation du nouveau défaut n'ont généralement pas été surveillées, du moins pas assez longtemps.

1.1.3.2 Exigences non fonctionnelles

Les exigences non fonctionnelles d'un système de diagnostic doivent rendre compte des propriétés qu'un tel système doit posséder.

Robustesse: Le système de diagnostic doit être robuste vis-à-vis des bruits de mesure et des incertitudes sur le modèle ou les règles de fonctionnement adoptées. Bien que l'augmentation de cette robustesse puisse être obtenue par une augmentation des seuils de tolérance, utilisés pour détecter un comportement anormal ou isoler un défaut apparu, elle peut néanmoins impacter les performances du système de diagnostic.

Adaptabilité: Le système de diagnostic étant couplé au système durant toute la durée de son exploitation, il doit pouvoir s'adapter aux modifications du système mais aussi intégrer facilement de nouveaux paramètres ou informations obtenus après son installation. En effet, les conditions opérationnelles du système peuvent évoluer à cause de perturbations ou de changements des conditions d'exploitation. Il faut donc que le système de diagnostic puisse s'adapter à tous changements potentiels.

Implantation: Selon le type de défauts à diagnostiquer, deux types d'implantations peuvent être adoptés [8] : une implantation embarquée (on-board) ou une implantation débarquée (off-board). Les performances désirées du système de diagnostic impliquent un besoin en espace de stockage et en puissance de calcul. En étant embarqué, le

système de diagnostic doit fonctionner avec des contraintes de puissance de calcul et d'espace de stockage pouvant limiter la complexité de l'algorithme de diagnostic. Un compromis peut donc être à trouver entre les performances du système de diagnostic et les performances du matériel utilisé pour son implantation. En débarqué, le système de diagnostic a une capacité de puissance de calcul et d'espace de stockage « quasi illimitée », mais doit néanmoins traiter des données limitées voire biaisées.

Estimation des erreurs du système de diagnostic: Il s'agit de déterminer la confiance que peut avoir l'utilisateur final du système sur la fiabilité du système de diagnostic : ses erreurs potentielles de diagnostic (fausses alarmes, non détections ou encore mauvaises isolations). Cela peut se faire en établissant au préalable une estimation et une classification des erreurs pouvant être faites par le système de diagnostic, ce qui pourra ainsi accroître sa fiabilité car l'opérateur aura l'opportunité de mieux interpréter les conclusions du système de diagnostic suite à ces estimations d'erreurs.

1.4 Les méthodologies de diagnostic

Les deux principales composantes d'un système de diagnostic sont d'une part le type de connaissance a priori du système ainsi que les défauts potentiels, et d'autre part la technique de recherche utilisée pour diagnostiquer les défauts. Sachant que la technique de recherche dépend fortement des connaissances disponibles il est donc plus judicieux d'adopter une classification basée sur la connaissance du système. C'est d'ailleurs traité comme cela dans [6], qui réalise un important état de l'art des différentes méthodologies de diagnostic, ou dans [7] qui incorpore une classification des méthodologies de diagnostic dans un important état de l'art de la surveillance automatique).

Les différentes techniques de recherche des méthodes de diagnostic ont pour principe de fonctionnement une comparaison du fonctionnement réel du système à une référence illustrant son fonctionnement normal ou ses fonctionnements anormaux. Elles exploitent donc, toutes une certaine forme de redondance de l'information. Cette redondance peut être développée à partir de la compréhension du système par l'utilisation de modèles, c'est l'approche dite à base de modèles. Par contraste, elle peut provenir des expériences passées sur le système, c'est l'approche dite à base de données.

Indiquons néanmoins le premier type de redondance qui est la redondance physique ou matérielle. Cette technique consiste à doubler ou mieux tripler les capteurs, actionneurs, processeurs et logiciels du système pour mesurer et/ou contrôler des variables

particulières. La comparaison des grandeurs redondantes permet ainsi de décider si un défaut est présent ou non. Néanmoins et même si cette méthode de diagnostic s'avère fiable et simple à implanter, elle entraîne bien évidemment un surcoût important en instrumentation et s'avère ainsi mise en œuvre essentiellement sur des systèmes à hauts risques tels que les centrales nucléaires ou en aéronautique.

1.4.1 Les méthodes de diagnostic à base de modèles

Les méthodes de diagnostic à base de modèles consistent à comparer le comportement réellement observé du système à un comportement prédit, issu d'un modèle de fonctionnement de ce système. Ces méthodes furent développées dès le début des années 70 et fortement intenses durant les années 80 et 90, dont les principaux travaux de référence du domaine sont [10], [11], [12] ainsi que [13], le diagnostic à base de modèles est toujours un domaine de recherche en expansion de nos jours. Les modèles utilisés par ces méthodes peuvent être de deux types : les modèles quantitatifs et les modèles qualitatifs.

1.4.1.1 Le diagnostic à base de modèles quantitatifs

Ce sont les méthodes utilisées par la communauté de l'automatique et plus connues sous le terme de Model-Based Fault Detection and Isolation (dont l'acronyme est FDI). L'utilisation d'un modèle de bon fonctionnement du système permet d'engendrer des incompatibilités entre le comportement réel du système et celui prédit par le modèle. Ces incompatibilités, appelées indicateurs de défauts ou résidus, sont générées à partir des mesures effectuées sur les variables connues du système (i.e. : ses entrées et ses sorties) et de calculs fondés sur le modèle du système. Ces résidus, notés r_i , sont des signaux devant refléter la cohérence des données mesurées du système par rapport au modèle de fonctionnement. L'objectif d'un résidu r_i est d'être sensible aux défauts : c'est-à-dire qu'il doit refléter l'éventuelle présence d'un défaut. Cela signifie donc qu'un résidu est en général proche d'une valeur de référence si aucun défaut n'affecte le système, et qu'il est dévié vers une valeur différente de celle qu'il avait lors du fonctionnement normal dès qu'un défaut apparaît. Ce sont ces résidus qui sont ensuite évalués pour réaliser les différentes fonctions du diagnostic.

Comme le montre la figure 1.2, ces méthodes de diagnostic nécessitent deux étapes :

- La première étape génère les résidus r_i à partir des mesures effectuées sur les variables connues du système (i.e. : ses variables d'entrées et de sorties).

- La seconde étape est une règle de décision pour le diagnostic basée sur ces résidus ri générés. Plusieurs méthodes de génération de résidus existent et nous allons présenter les plus fréquemment utilisées.

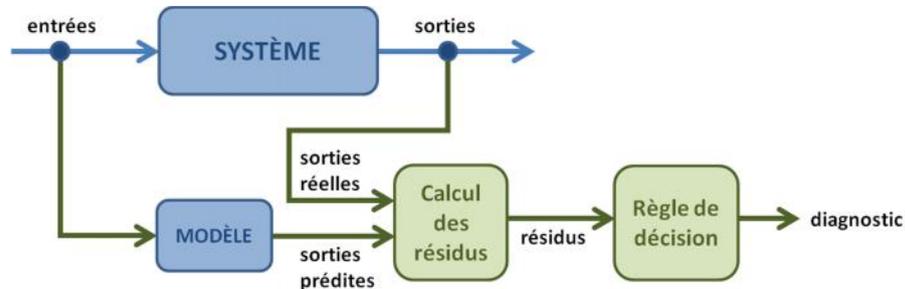


Figure 1.3 Étapes du diagnostic à base de modèles.

Approche d'identification: Il s'agit d'une approche pour laquelle le résidu est engendré par la différence entre les estimations en ligne des paramètres du modèle du système et les paramètres nominaux du système définis pour un fonctionnement normal. L'erreur d'estimation est ainsi utilisée comme résidu [14]. Bien que cette méthode soit bien adaptée aux défauts de paramètres, leurs conditions d'estimation restent néanmoins très contraignantes et le retour aux paramètres physiques du système n'est pas toujours possible [16].

Approche de l'espace de parité: Cette approche, introduite par [15] a pour principe de transformer les équations du modèle de manière à obtenir des relations particulières appelées des relations de redondance analytique (dont l'acronyme est RRA). Ces relations n'utilisent que des grandeurs connues et disponibles en ligne du système et les résidus sont alors obtenus en substituant dans ces relations les variables connues par leurs valeurs réelles, prélevées sur le système en fonctionnement. L'ensemble des valeurs que peuvent prendre les résidus compose alors un espace appelé espace de parité, comportant autant de dimensions qu'il existe de résidus. Dans cet espace, le vecteur de parité y est défini comme la valeur des résidus à un instant donné et prend alors une direction dans le cas de l'apparition d'un défaut. Tout l'enjeu consiste alors à transformer l'espace de parité de départ en un espace permettant de découpler les défauts : c'est-à-dire que chaque défaut soit uniquement représentatif d'un élément du vecteur.

Approches à base d'observateurs: Les approches à base d'observateurs ou de filtres,

bien connues du monde de l'automatique à des fins de commande en boucle fermée, sont les plus couramment utilisées et les premiers travaux datent des années 70 [16] et [17]. Le principe général étant de concevoir un système permettant de donner une image (ou estimation) de certaines variables nécessaires au bouclage, l'adaptation à des fins de diagnostic consiste donc à comparer les sorties mesurées avec des sorties estimées. C'est l'écart entre ces valeurs qui est alors utilisé comme résidu.

L'inconvénient majeur de ces méthodes reste néanmoins la nécessité de disposer d'un modèle relativement précis du système. Remarquons que lorsque ces méthodes utilisent des modèles linéaires, la théorie est bien développée. Par contre pour les systèmes non linéaires et comme dans le cas du contrôle-commande, il est nécessaire de travailler autour d'un point de fonctionnement pour cause de contraintes de complexité de calcul [9]. Ceci réduit ainsi grandement le champ d'application de ces techniques.

1.4.1.2 Le diagnostic à base de modèles qualitatifs

Ce sont les méthodes généralement utilisées par la communauté de l'intelligence artificielle et dont l'acronyme est DX pour Data eXtraction. Les modèles qualitatifs permettent d'abstraire, à un certain degré, le comportement du système à travers des modèles de type symbolique. Ces modèles décrivent d'une manière qualitative l'espace d'état continu du système et ne représentent pas la physique du système, contrairement aux modèles quantitatifs, car ils le décrivent en terme de mode de fonctionnement. Les méthodes à base de modèles qualitatifs peuvent être classifiées de deux manières :

- Soit selon le niveau d'abstraction considéré du système à diagnostiquer. Les systèmes continus où les approches ont été développés à base de graphes causaux [18] et de graphes causaux temporels [19]. Les systèmes à événements discrets, dont la référence de la littérature est [20], consistent à représenter le système par des automates à états finis. Les systèmes hybrides dynamiques où nous pouvons trouver des méthodes reposant sur des modèles hybrides tels que les automates hybrides à temps discret [21], les bond-graphs [22] ou les réseaux de Petri hybrides [23].
- Soit selon la prise en compte, ou non, des défauts : les modèles de dysfonctionnement comme dans les techniques de propagation des défauts ou pour les graphes causaux, ou les modèles de bon fonctionnement dans le cas du diagnostic à partir des principes premiers ou par simulation qualitative.

1.4.2 Les méthodes de diagnostic à base de données "Modèles boîte noire"

Contrairement aux méthodes à base de modèles, celles à base de données reposent sur un nombre important de données qui sont supposées représenter convenablement le système. Les seules informations disponibles sont les signaux issus des capteurs du système.

Lorsque les seules informations disponibles sur le système proviennent des signaux d'entrée et de sortie du système, le traitement numérique des données entrée/sortie conduit à la construction de modèles de type « boîte noire ». Qui ont pour principale caractéristique d'utiliser "en aveugle" les données sans autre considération physique. Les modèles économétriques, les réseaux de neurones artificiels et les réseaux d'ondelettes sont des exemples de tels modèles.

Les réseaux de neurones artificiels fonctionnent de façon analogue à un réseau de neurones biologiques et sont caractérisés par leur capacité d'apprentissage qui va dépendre du processus d'acquisition et de la couverture des données.

Un exemple de méthode d'apprentissage est la reconnaissance de formes qui s'applique dès lors que l'ensemble d'apprentissage couvre plusieurs modes de fonctionnement bien répertoriés du procédé. Une forme représente un ensemble de n paramètres vu comme un point de l'espace de dimension n . La reconnaissance de formes consistera à associer à une forme donnée une forme-type connue. Compte tenu des perturbations liées à l'observation d'une forme, une zone dans l'espace de représentation peut être attribuée à chaque forme-type : c'est la notion de classe. Le principe de la reconnaissance est donc d'associer chaque nouvelle forme observée à une classe connue. Des classes pourront être associées à des causes de défaillance du système.

Les méthodes de traitement du signal génèrent également des systèmes de diagnostic. Le principe de ces systèmes est d'utiliser les propriétés statistiques des mesures effectuées sur le processus comme indicateurs de défauts, le modèle du système se réduit alors à la connaissance de valeurs de référence pour ces paramètres statistiques.

1.5 Conclusion

Notre travail consiste à appliquer certaines méthodes de traitement de signal, à savoir l'analyse en ondelette, l'analyse en composante principale et l'analyse en composante indépendante pour extraire les anomalies (défauts) dans les systèmes. Le principe est de générer les résidus entre l'état normal et celui anormal, dans un but de les intégrer dans un système de diagnostic reliant l'effet (résidu) au défaut.

Pour le faire trois chapitres ont été développés, chapitre 2 porte sur "L'analyse spectrale haute résolution", chapitre 3 "Les réseaux d'ondelettes et l'analyse en composante principale" et le chapitre 4 "L'analyse en composante indépendante, séparation aveugle des sources". Les trois chapitres portent sur le développement mathématique des techniques proposées pour caractériser les défauts.

1.6 Références bibliographiques

- [1] Michel Batteux, *Diagnosticabilité et diagnostic de systèmes pilotés*, Thèse de Doctorat, université de Paris-Sud, 2011.
- [2] Rabah Fellouah, *Contribution au diagnostic de panne pour les systèmes différentiellement plats*, Thèse de Doctorat, INSA de Toulouse, 2007.
- [3] R. Isermann : *Fault-Diagnosis Systems*. Springer-Verlag, 2006.
- [4] M. Batteux, P. Fiani, P. Dague et N. Rapin : *Fuel cell system improvement for model-based diagnosis analysis*. IEEE Vehicle Power and Propulsion Conference, VPPC, Lille, France, September 1-3, 2010.
- [5] M. Basseville : *On fault detectability and isolability*. Rapport de recherche IRISA no 1240, 1999.
- [6] V. Venkatasubramanian, R. Rengaswamy, K. Yin et S.N. Kavuri : *A review of process fault detection and diagnosis*. 'part I to III'. Computers and Chemical
- [7] Y. Papadopoulos et J. McDermid : *Automated safety monitoring : a review and classification of methods*. International Journal of Condition Monitoring and Diagnostic Engineering Management, 2001.
- [8] M. Blanke, M. Kinnaert, J. Lunze et M. Staroswiecki : *Diagnosis and fault-tolerant control*. Springer-Verlag, 2003.
- [9] J. Brunet, D. Jaume, M. Labarrère, A. Rault et M. Vergé : *Détection et diagnostic de pannes*. Hermès, 1990.
- [10] R.J. Patton, P.M. Frank et R.N. Clark : *Fault diagnosis in Dynamic systems : theory and application*. Prentice Hall, 1989.
- [11] M. Basseville et I.V. Nikiforov : *Detection of Abrupt Changes : Theory and Application*. Prentice-Hall, 1993.
- [12] J.J. Gertler : *Fault Detection and Diagnosis in Engineering Systems*. Marcel Dekker Inc., 1998.
- [13] J. Chen et R.J. Patton : *Robust Model-based Fault Diagnosis for Dynamic Systems*. Kluwer Academic Publishers, 1999.
- [14] R. Isermann : *Process fault detection based on modelling and estimation*. Automatica, 20(4):387–404, 1984.
- [15] A.S. Willsky : *A survey of design methods for failure detection in dynamic systems*. Automatica, 12:601–611, 1976.
- [16] R.N. Clark, D.C. Fosth et W.M. Walton : *Detecting instrument malfunctions in control systems*. IEEE Transactions on Aerospace and Electronic Systems. 11(4):465–473, 1975.

- [17] H.L. Jones : *Failure Detection in Linear System*. Thèse de doctorat, MIT, Cambridge, 1973.
- [18] K. Bousson, J. Steyer, L. Travé-Massuyès et B. Dahhou: *From a rule-base to a predictive qualitative model-based approach using automated model generation. Application to the monitoring and diagnosis of biological process*. Engineering Applications of Artificial Intelligence, 11:477–493, 1998.
- [19] J. Mosterman : *Diagnosis of physical systems with hybrid models using parameterised causality*. Hybrid Systems: Computation and Control, 4th International Workshop, pages 447–458, 2001.
- [20] M. Sampath, R. Sengupta, S. Lafortune, K. Sinnamohideen et D. Teneketzis: *Diagnosability of discrete event systems*. IEEE Transactions on Automatic Control, 1995.
- [21] P. Bhowal, D. Sarkar, S. Mukhopadhyay et A. Basu : *Fault diagnosis in discrete time hybrid systems - a case study*. Information Sciences, 177(5):1290–1308, 2007.
- [22] M. Tagina, J.P. Cassar, G. Dauphin-Tangy et M. Staroswiecki: *Monitoring of systems modelled by bond graph*. International Conference on Bond Graph Modeling and Simulation, pages 275–280, 1995.
- [23] M. Gomaa et S. Gentil : *Hybrid industrial dynamical system supervision via hybrid continuous causal petri nets*. IEEE SMC IMACS Symposium on Discrete Events and Manufacturing Systems, pages 380–384, 1996.

2. Chapitre 2 : Analyse spectrale haute résolution

2.1 Problématique de l'Analyse spectrale

La représentation du signal sous la forme $x(t)$ est une démarche naturelle mais elle ne correspond pas forcément à la meilleure représentation physique des signaux rencontrés. En effet, l'individu ou les systèmes électroniques sont souvent plus sensibles à la puissance et à la fréquence des signaux. La représentation du signal sous la forme de sa répartition de puissance en fonction de la fréquence permet, dans bien des cas, d'extraire de manière plus immédiate l'information qui réside dans ce dernier [1, 2]. Globalement, le problème d'analyse spectrale se pose lorsqu'il s'agit d'estimer une densité spectrale de puissance (DSP), $\chi_x(\nu)$ de N échantillons connus d'un signal x .

Mathématiquement, la DSP est calculée à partir d'une infinité d'échantillons du signal. Or, nous ne disposons que de N points, il est nécessaire de faire des hypothèses sur les points en dehors de la fenêtre d'observation :

L'hypothèse la plus classique consiste à estimer la fonction de corrélation sur les N points du signal; les autres points sont mis à zéro. Cela conduit aux méthodes mettant la transformée de Fourier (corrélogramme, périodogramme moyenné).

Le second type d'hypothèse revient à extrapoler la fonction de corrélation en dehors de son support par des valeurs qui maximisent le flux d'entropie du signal (MEM : Maximum Entropie Method). Maximiser l'entropie du signal consiste à contraindre le moins possible le signal en dehors de son support connu.

Pour un processus gaussien, la méthode MEM revient à maximiser la fonction

$$H = \int_{-\infty}^{+\infty} \text{Log}(\chi_x(\nu)) d\nu \quad (2.1)$$

On montre que les méthodes MEM sont équivalentes aux méthodes par prédiction linéaire. Cela nous conduit aux méthodes paramétriques autorégressives.

2.2 Méthodes non paramétriques

Le *Périodogramme* moyenné et le *Corrélogramme* sont deux techniques courantes [1, 2]. La première technique fait la moyenne des FFT complexe du processus découpé en N tranches. La seconde utilise le théorème de Wiener-Khintchine : autocorrélation et DSP forment une paire de transformée de Fourier pour une séquence courte (46 points), on préfère employer le corrélogramme pour des raisons de temps de calcul qui sont inférieurs à ceux du périodogramme.

Pour diminuer les effets d'extrémités des séquences, on les force à zéro par une fenêtre de Tuckey (corrélation entre une fenêtre de Hamming de 16 points et une fenêtre rectangulaire de N points) est préférée aux autres par la perte minimale qu'elle implique aux extrémités. L'estimateur du spectre DSP d'une séquence $x(n)$ est obtenu comme suit :

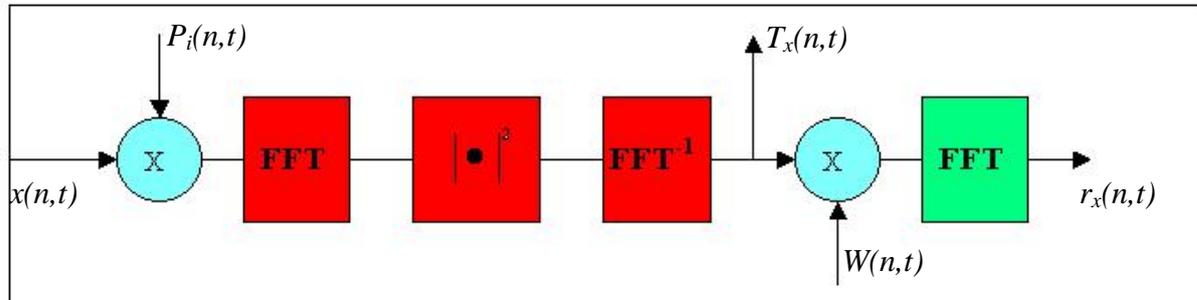


Figure 2.2 Estimateur du spectre DSP.

P_i : fenêtre de pondération temporelle (Tuckey); i : tranche N° i ;

r_x : autocorrélation de x ; W : fenêtre de Hamming à la puissance 2.

Les statistiques d'estimations spectrales sont fixées par les fenêtres de pondération W et P . On définit sa «puissance de moyennage» comme le produit du temps d'intégration T_i par la bande équivalente du bruit blanc B_e . Dans l'hypothèse de processus gaussiens, la variance de l'estimation vaut : $Var(r_{xx}^2(v)/B_e T_i)$.

2.2.1 Périodogramme, Corrélogramme

La Transformée de Fourier de la fonction d'autocorrélation $r_{xx}(\ddagger)$ du processus aléatoire $x(t)$ stationnaire d'ordre 2 s'écrit:

$$P(f) = \int_{-\infty}^{+\infty} r_{xx}(\ddagger) e^{-j2f\ddagger} d\ddagger \quad (2.2)$$

elle est égale à la densité spectrale de puissance $P(f)$ du processus $x(t)$.

En effet, pour $\ddagger = 0$, il vient:

$$r(0) = E[x(t)^2] = \int_{-\infty}^{+\infty} P(f) e^{j2f \cdot 0} df = \int_{-\infty}^{+\infty} P(f) df \quad (2.3)$$

En supposant l'hypothèse ergodique vérifiée, l'espérance mathématique s'écrit:

$$E[x(t)^2] = \lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^{+T} x(t)^2 dt = \int_{-\infty}^{+\infty} P(f) df \quad (2.4)$$

$P(f)$ représente donc bien la densité spectrale de puissance du processus $x(t)$. Il s'agit là du théorème de Wiener Khintchine.

L'hypothèse ergodique permettant de confondre l'espérance mathématique avec une moyenne temporelle, le développement de $r(\dagger)$ donne :

$$p(f) = \int_{-\infty}^{+\infty} \left[\lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^T x(t)x^*(t-\dagger) \right] e^{-j2f\dagger} d\dagger$$

Nous pouvons aussi introduire le spectre complexe de la réalisation tronquée du processus $x(t)$:

$$X_{2T}(f) = \int_{-T}^{+T} x(t)e^{-j2ft} dt \quad (2.5)$$

En prenant le carré de cette expression, il vient :

$$\frac{1}{2T} |X_{2T}(f)|^2 = \frac{1}{2T} \int_{-T-T}^{+T+T} x(u)x^*(v) e^{-j2ffu} e^{+j2ffv} dudv \quad (2.6)$$

et en prenant l'espérance de cette expression, nous obtenons la relation suivante:

$$E \left[\frac{1}{2T} |X_{2T}(f)|^2 \right] = \frac{1}{2T} \int_{-T-T}^{+T+T} r_{xx}(u-v) e^{-j2ff(u-v)} dudv \quad (2.7)$$

En effectuant alors le changement de variable suivant:

$$\begin{cases} \dagger = u - v \\ v' = v \end{cases} \quad (2.8)$$

Et en prenant garde aux intervalles de variation des nouvelles variables, il vient :

pour $\dagger \geq 0$; v' varie de $-T$ à $+T$ et pour $\dagger \leq 0$; v' varie de T à $-T-\dagger$

$$E \left[\frac{1}{2T} |X_{2T}(f)|^2 \right] = \frac{1}{2T} \int_{\dagger=0}^{-2T-T-\dagger} \int_{v'=-T}^{-T-\dagger} r_{xx}(\dagger) e^{-j2ff\dagger} d\dagger dv' + \int_{\dagger=0}^{-2T-T-\dagger} \int_{v'=T}^{-T-\dagger} r_{xx}(\dagger) e^{-j2ff\dagger} d\dagger dv' \quad (2.9)$$

$$E \left[\frac{1}{2T} |X_{2T}(f)|^2 \right] = \frac{1}{2T} \int_{\dagger=0}^{-2T} r_{xx}(\dagger)(2T - |\dagger|) e^{-j2ff\dagger} d\dagger + \int_{\dagger=0}^{-2T} r_{xx}(\dagger)(-2T + |\dagger|) e^{-j2ff\dagger} d\dagger \quad (2.10)$$

d'où finalement :

$$E \left[\frac{1}{2T} |X_{2T}(f)|^2 \right] = \int_{\dagger=0}^{-2T} r_{xx}(\dagger) \left(1 - \frac{|\dagger|}{2T}\right) e^{-j2ff\dagger} d\dagger \quad (2.11)$$

En introduisant alors la fonction I_{4T} indicatrice de l'intervalle $T, +2T$, , il vient :

$$E\left[\frac{1}{2T}|X_{2T}(f)|^2\right] = TF\left[r_{xx}(\frac{\cdot}{2T})\left(1-\frac{|\cdot|}{2T}\right)I_{4T}\right] \quad (2.12)$$

Nous obtenons donc :

$$E\left[\frac{1}{2T}|X_{2T}(f)|^2\right] = \left[P(f) * TF\left(1-\frac{|\cdot|}{2T}\right)I_{4T}\right] \quad (2.13)$$

Lorsque T tend vers l'infini, le deuxième terme du produit de convolution tend vers $u(f)$, d'où :

$$\lim_{T \rightarrow \infty} E\left[\frac{1}{2T}|X_{2T}(f)|^2\right] = [P(f)] \quad (2.14)$$

En considérant alors un cas numérique, où l'observation du signal $x(t)$ se résume à N valeurs échantillonnées à la période T_e , la densité spectrale peut être estimée en limitant l'intégrale précédente et en oubliant l'espérance mathématique.

D'où :

$$P_{per}(f) = \frac{1}{NT_e} \left| \sum_{n=0}^{N-1} x(nT_e) e^{-j2fnT_e f} \right|^2 \quad (2.15)$$

Cet estimateur de la densité spectrale de puissance du signal $x(nT_e)$ est appelé *périodogramme*. Il demande, pour être calculé, la mise au carré de la Transformée de Fourier du signal numérique $x(nT_e)$ sur N points. Il est, depuis la mise au point de l'algorithme de Transformation de Fourier Rapide (TFR ou FFT en anglais) par J. Cooley et J. Tuckey en 1965, l'estimateur le plus employé. Jusqu'à la mise au point de l'algorithme de la FFT, la méthode la plus utilisée consistait à estimer N' valeurs de la fonction d'autocorrélation $r(p)$ avec $N' < N$ et à calculer la Transformée de Fourier Discrète (TFD ou DFT en anglais) sur les N' points obtenus. Cet estimateur de la densité spectrale de puissance, du aux travaux de Blackman et Tuckey, porte le nom de *corrélogramme*.

$$P_{cor}(f) = \sum_{p=-(N'-1)}^{N'-1} r_{xx}(p) e^{-j2fpf} \quad (2.16)$$

$$\text{avec: } r(p) = \frac{1}{N} \sum_{n=p}^{N-1} x(n)x(n-p)^* \quad (2.17)$$

pour $p=0 \rightarrow N' - 1$

Pour $N = N'$ les estimateurs du *périodogramme* et du *corrélogramme* sont identiques.

En effet,

$$P_{cor}(f) = \frac{1}{N} \sum_{p=-(N-1)}^{N-1} \sum_{n=p}^{N-1} x(n)x(n-p) * e^{-j2fpf} \quad (2.18)$$

d'où:

$$P_{cor}(f) = \frac{1}{N} \sum_{p=-(N-1)}^{N-1} \sum_{n=p}^{N-1} x(n)e^{-j2fnf} x(n-p) * e^{-j2fpf} \quad (2.19)$$

expression qui peut encore s'écrire:

$$P_{cor}(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n)e^{-j2fnf} \right|^2 = P_{per}(f) \quad (2.20)$$

Les deux estimateurs sont donc bien identiques pour $N = N'$.

2.2.1.1 Propriétés du corrélogramme

Le corrélogramme constituant un estimateur de la densité spectrale de puissance du processus $x(nTe)$, il est nécessaire d'étudier son biais et sa variance.

Le calcul de l'espérance de $P_{cor}(f)$ donne:

$$E[P_{cor}(f)] = E \left[\sum_{p=-(N-1)}^{N-1} r_{xx}(p) e^{-j2fpf} \right] \quad (2.21)$$

avec :

$$r(p) = \frac{1}{N} \sum_{n=p}^{N-1} x(n)x(n-p) * \quad (2.22)$$

d'où:

$$E[P_{cor}(f)] = \sum_{p=-(N-1)}^{N-1} r_{xx}(p) \frac{N-|p|}{N} e^{-j2fpf} \quad (2.23)$$

encore grâce aux propriétés de la Transformée de Fourier:

$$E[P_{cor}(f)] = P(f) * N \left(\frac{\sin fN}{N \sin ff} \right)^2$$

L'estimateur du corrélogramme est donc une estimation biaisée de la densité spectrale de puissance $P(f)$ du processus $x(nTe)$. L'estimateur est en fait le résultat du filtrage, dans le

domaine fréquentiel de $P(f)$ par le filtre $N \left(\frac{\sin fN}{N \sin ff} \right)^2$.

Lorsque N tend vers l'infini ce filtre tend vers $u(f)$, le corrélogramme est donc asymptotiquement sans biais.

Le calcul de la variance est délicat et conduit, pour des signaux gaussiens à :

$$\text{var}(P_{cor}(f)) = P(f) \left[1 + N \left(\frac{\sin(2ffN)}{2ffN} \right)^2 \right]$$

Cette variance peut être diminuée en séparant l'ensemble des N valeurs de $x(nTe)$ en $\frac{N}{K}$ sous-ensembles de KN valeurs. Il est alors possible de calculer K estimateurs et de faire la moyenne des K estimateurs obtenus. La variance est alors divisée par K^2 . Cette amélioration de la variance de l'estimateur se paye par une diminution de résolution de ce dernier. En effet la résolution spectrale est en $\frac{1}{NTe}$ dans le cas de N échantillons et en $\frac{1}{KTe}$ dans le cas de K échantillons.

Enfin, les lobes secondaires de $N \left(\frac{\sin ffn}{ffN} \right)^2$ peuvent être atténués en introduisant des fenêtres de pondérations appliquées directement sur le signal observé $x(nTe)$.

En conclusion, le corrélogramme est un estimateur de la densité spectrale de puissance qui est d'autant meilleur que le signal est observé sur une longue plage de stationnarité. L'algorithme de la Transformée de Fourier Rapide est bien connu et la plupart des processeurs de signaux sont vendus avec des routines de TFR optimisées. Cet estimateur est donc aisé à être utilisé et c'est la raison pour laquelle c'est l'estimateur le plus employé aujourd'hui. Pour calculer un périodogramme il faut donc:

- observer N valeurs du signal $x(nT_e)$.
- calculer une TFR sur N points avec mise au carré.

2.2.2 Méthode du minimum de variance (Méthode de Capon)

Pour chaque fréquence f , cette méthode cherche un *filtre adapté* dont la réponse vaut 1 pour cette fréquence f et 0 partout ailleurs. Une fois ce filtre obtenu, l'estimateur $P_{Cap}(f)$ n'est autre que la puissance de sortie du filtre obtenu pour la fréquence f .

La sortie $y(n)$ de ce filtre s'écrit:

$$y(n) = \sum_{i=0}^N h_i^* x(n-i) \quad (2.26)$$

ou plus simplement sous forme vectorielle :

$$y(n) = H^T X(n) ; \text{ avec : } H = \begin{bmatrix} h_0 \\ h_1 \\ h_2 \\ \vdots \\ h_N \end{bmatrix} \quad \text{et} \quad X(n) = \begin{bmatrix} x(n) \\ x(n-1) \\ x(n-2) \\ \vdots \\ x((n-N)) \end{bmatrix} \quad (2.27)$$

Le filtre H doit donc minimiser $E[y(n)^2]$ avec la contrainte $H^T F = 1$ avec :

$$F = \begin{bmatrix} 1 \\ e^{j2ff} \\ e^{j4ff} \\ \vdots \\ e^{j2Nf} \end{bmatrix} \quad (2.28)$$

Ce qui s'écrit, en utilisant un multiplicateur de Lagrange;

H est optimal si est seulement si

$$E[H^T X(n)]^2 + \gamma (1 - H^T F) \quad (2.29)$$

est minimal, soit, en annulant la dérivé par rapport à H ; alors

$$H = \frac{\gamma}{2} R_N^{-1} F \quad (2.30)$$

avec :

$$R_N E[X(n)X(n)^T] \quad (2.31)$$

matrice d'autocorrélation du signal $x(n)$.

En introduisant α dans l'expression de la contrainte $H^T F = 1$, il vient :

$$\gamma = \frac{2}{F^T R_N^{-1} F} \quad (2.32)$$

d'où finalement :

$$H = \frac{R_N^{-1} F}{F^T R_N^{-1} F} \quad (2.33)$$

Pour estimer $P_{Cap}(f)$ il ne reste plus qu'à calculer:

$$P_{cap}(f) = E[y(n)^2] = E[H^T X(n)X(n)^T H] \quad (2.34)$$

$$P_{Cap}(f) = \frac{F^T R_N^{-1} R_N R_{N+1}^{-1} F}{F^T R_N^{-1} F F^T R_N^{-1} F} \quad (2.35)$$

$$P_{Cap}(f) = \frac{1}{F^T R_N^{-1} F} \quad (2.36)$$

Or:

$$F^T R_N^{-1} F = [1, e^{-j2ff}, e^{-j4ff}, \dots, e^{-j2Nff}] \begin{bmatrix} \dots_{KL} \\ \left[\begin{array}{c} 1 \\ e^{j2ff} \\ \vdots \\ e^{j2Nff} \end{array} \right] \end{bmatrix} \quad (2.37)$$

D'où:

$$P_{Cap}(f) = \frac{1}{\sum_{k=0}^N \sum_{l=0}^N \dots_{kl} e^{-j2ff(k-l)}} \quad (2.38)$$

En conclusion, pour obtenir l'estimateur de Capon, il faut:

- observer N échantillons du signal $x(nTe)$;
- estimer la matrice d'autocorrélation et l'inverser pour obtenir les termes \dots_{kl} ;
- calculer $P_{Cap}(f)$ pour chaque fréquence f ;

Cette méthode souffre donc d'un coût de calcul supérieur aux estimateurs précédents. Il est possible de démontrer que cet estimateur a une variance minimale et c'est la raison pour laquelle il est souvent appelé estimateur du minimum de variance.

2.3 Méthodes Autorégressives

L'estimation spectrale paramétrique, contrairement aux méthodes non-paramétriques qui réalisent une transformée de Fourier discrète sur l'ensemble des données disponibles, comprend trois étapes [3, 4]:

- Dans la première étape un modèle approprié est sélectionné pour représenter les données mesurées (AR, ARMA).

- Dans la deuxième étape nous estimons les paramètres du modèle choisi.
- Dans la troisième étape nous estimons la densité spectrale de puissance.

Le modèle de la série temporelle qui approxime plusieurs processus déterministes et stochastiques rencontrés en pratique est représenté par l'équation aux différences d'un filtre linéaire suivant:

$$x(n) = \sum_{k=0}^{\infty} h(k)u(n-k) \tag{2.39}$$

où $x(n)$ est la séquence de sortie d'un filtre causal ($h(k)=0$ pour $k < 0$) et qui présente les données d'observations et $u(n)$ est la séquence d'entrée.

La fonction de transfert est donnée par:

$$H(z) = \frac{B(z)}{A(z)} \tag{2.40}$$

On peut prendre $b(0)=1$ parce que l'entrée peut être graduée de telle façon que le filtre ne contient pas un gain. Donc on peut écrire les polynômes $H(Z)$, $B(Z)$ et $A(Z)$ sous les formes suivantes:

$$\begin{aligned} A(z) &= 1 + \sum_{k=1}^p a_k z^{-k} \\ B(z) &= 1 + \sum_{k=1}^q b_k z^{-k} \\ H(z) &= 1 + \sum_{k=1}^{\infty} h_k z^{-k} \end{aligned} \tag{2.41}$$

Les deux polynômes $A(Z)$ et $B(Z)$ doivent être choisis de telle sorte à avoir tous les zéros à l'intérieur du cercle d'unité pour assurer la stabilité, le déphasage minimale, la causalité et le filtre inverse stable

2.3.1 Modèle MA (Moyenne Mobile)

Les signaux à moyenne mobile sont obtenus par passage d'un bruit blanc dans un filtre purement transverse. Ce filtre est aussi appelé filtre à réponse impulsionnelle finie (R.I.F). L'équation de récurrence reliant la sortie x_n au signal d'entrée u_n est de la forme :

$$x_n = b_0 u_n + b_1 u_{n-1} + \dots + b_m u_{n-m} \tag{2.42}$$

La fonction de transfert de ce filtre prend la forme :

$$H(z) = \sum_{i=0}^m b_i z^{-i} \tag{2.43}$$

Bien que l'expression du filtre paraisse simple, l'obtention des coefficients b_i est en fait un problème complexe. Supposons à titre d'exemple que nous voulons modéliser un signal x_n comme étant un signal MA, si on suppose de plus que le bruit d'entrée est centré et stationnaire ($E(u_n)=0$), nous pouvons alors écrire :

$$x_{n-k} = b_0 u_{n-k} + b_1 u_{n-k-1} + \dots + b_m u_{n-k-m} \tag{2.44}$$

Nous obtenons alors :

$$E[x_n x_{n-k}] = E[(b_0 u_n + \dots + b_m u_{n-m}) \cdot (b_0 u_{n-k} + \dots + b_m u_{n-k-m})]. \tag{2.45}$$

Nous supposons de plus que les réalisations du bruit d'entrée sont indépendantes, nous avons alors :

$$E[u_i u_j] = E(u_i)E(u_j) = 0 \text{ si } i \neq j \quad E[u_i^2] = \dagger_u^2 \tag{2.46}$$

Nous obtenons :

$$E[x_n x_{n-k}] = \dagger_u^2 (b_0 b_k + b_1 b_{k-1} + \dots + b_{k-m} b_m), \quad |k| < m \tag{2.47}$$

Nous pouvons remarquer d'après l'équation (2.43) que la fonction d'autocorrélation devient nulle à partir d'un décalage k .

Si les quantités $E[x_n x_{n-k}]$ et \dagger_u^2 sont supposées connues, nous remarquons que la détermination des b_k nécessite la résolution d'un système d'équation non linéaires. De plus, ce système n'admet pas forcément une solution unique.

2.2.2 MODELE AR (Autorégressif)

Les signaux autorégressifs sont obtenus par passage d'un bruit blanc dans un filtre purement récursif. Ce filtre est donc de réponse impulsionnelle infinie. L'équation de récurrence reliant la sortie x_n au signal d'entrée u_n est de la forme [5, 6, 7, 8, 9]:

$$x_n = a_1 x_{n-1} + a_2 x_{n-2} + \dots + a_r x_{n-r} + u_n \tag{2.48}$$

Cette équation de récurrence s'écrit aussi sous une forme plus condensée :

$$x_n = a^T X_n + u_n \tag{2.49}$$

Avec : $a = [a_1, a_2, \dots, a_r]^T$ et $X_n = [x_{n-1}, x_{n-2}, \dots, x_{n-r}]^T$

la fonction de transfert de ce filtre est donnée par :

$$H(z) = \frac{1}{1 - \sum_{j=1}^r a_j z^{-j}} \quad (2.50)$$

La sortie x_n du filtre est du second ordre ; si le filtre est dynamique c'est-à-dire stable et causal ; la fonction de transfert du filtre doit avoir ses pôles à l'intérieur du cercle unité. Soit C le vecteur de corrélation entre x_n et X_n :

$$\begin{aligned} c &= E[x_n X_n] \\ c &= E[(a^T X_n + u_n) X_n] \\ c &= E[a^T X_n] + E[u_n X_n] \end{aligned} \quad (2.51)$$

Nous remarquons que $a^T X_n$ est scalaire et que u_n et X_n sont indépendants, la quantité précédente peut s'écrire :

$$c = E[X_n^T X_n] a + E(u_n) E(X_n) \quad (2.52)$$

En définissant la matrice de covariance du vecteur X_n et sachant que u_n est centré, le vecteur C s'écrit finalement

$$C = \Gamma a \quad (2.53)$$

Cette équation vectorielle est appelée équation normale ou équation de Yule-Walker. Si la matrice Γ est inversible alors le vecteur de régression peut être calculé à partir des r premières valeurs de la fonction de corrélation nous avons :

$$\Gamma^{-1} c = E(x^2) = a^T \Gamma a + \sigma_u^2 \quad (2.54)$$

2.2.3 Modèle ARMA (Auto Régressif à Moyenne Mobile)

Les signaux ARMA sont obtenus par passage d'un bruit blanc dans un filtre récursif appelé aussi filtre à réponse impulsionnelle infinie (R.I.I), ces signaux sont une combinaison des signaux AR et MA. La fonction de transfert du filtre présente un numérateur et un dénominateur [10] :

$$H(z) = \frac{\sum_{i=0}^m b_i z^{-i}}{\sum_{j=0}^r a_j z^{-j}} \quad (2.55)$$

La relation entre la fonction d'autocorrélation et les coefficients d'un modèle:

$$x(k) = \sum_{i=1}^p a_i x(k-i) + \sum_{i=0}^q b_i x(k-i) \quad (2.56)$$

En multipliant l'équation (2.56) par $x(k-\ell)$ on obtient:

$$x(k)x(k-\ell) = \sum_{i=1}^p a_i x(k-i)x(k-\ell) + \sum_{i=0}^q b_i x(k-i)x(k-\ell) \quad (2.57)$$

En prenant l'espérance mathématique:

$$E[x(k)x(k-\ell)] = E\left[\sum_{i=1}^p a_i x(k-i)x(k-\ell)\right] + \sum_{i=0}^q b_i E[x(k-i)x(k-\ell)]$$

$$R_{xx}(\ell) = -\sum_{i=1}^p a_i R_{xx}(\ell-i) + \sum_{i=0}^q b_i R_{xx}(\ell-i) \quad (2.58)$$

$$R_{xx}(\ell) = \begin{cases} \sum_{i=0}^q h(i) \dagger_e^2 u(\ell-i) & \ell \leq 0 \\ 0 & \ell > 0 \end{cases}$$

$$R_{xx}(\ell) = \begin{cases} R_{xx}(\ell), \ell < 0 \\ \sum_{i=1}^p a_i R_{xx}(\ell-i) + \dagger_e^2 \sum_{i=0}^{q-\ell} h(i) h_{i+\ell}, 0 \leq \ell \leq q \\ -\sum_{i=0}^q b_i h(-\ell+i) = \sum_{i=0}^{q-\ell} h(k) b_{k+\ell} \end{cases} \quad (2.59)$$

Cas d'un modèle AR $B(Z)=1$ ($q=0$) :

$$R_{xx}(\ell) = \begin{cases} R_{xx}(-\ell), \ell < 0 \\ -\sum_{i=1}^p a_i R_{xx}(\ell-i) + \dagger_e^2, \ell = 0 \\ -\sum_{i=1}^p a_i R_{xx}(\ell-i), \ell > 0 \end{cases} \quad (2.60)$$

Cas d'un modèle MA, $A(Z)=1$ ($p=0$) :

$$R_{xx}(\ell) = \begin{cases} R_{xx}(-\ell), \ell < 0 \\ \dagger_e^2 \sum_{i=0}^q b_i b_{i+\ell}, 0 \leq \ell \leq q \\ 0, \ell > 0 \end{cases} \quad (2.61)$$

2.4 Méthode de la prédiction linéaire

La prédiction linéaire est un cas particulier du filtrage optimal de Wiener, dans lequel la sortie du système à modéliser et à identifier n'est autres que le signal d'entrée mais décalé dans le temps [11, 12]. Reprenons le modèle AR : $x_n = a^T X_n + u_n$ si on néglige $u(k)$, la quantité :

$$\hat{x}_n = a^T X_n \quad (2.62)$$

apparaît comme la prédiction du signal x_n à l'instant n , connaissant les P échantillons antérieurs.

Soit \hat{x}_n ce signal prédit, u_n apparaît alors comme l'erreur de prédiction. Les coefficients a_k sont appelés coefficients de prédiction.

Pour déterminer les coefficients a_k (ce qui revient à identifier le système AR) il faut minimiser le critère d'optimisation suivant:

$$J = \sum_{k=0}^N x^2(k) = \sum_{k=0}^N [y(k) - \hat{y}(k)]^2 = \sum_k \left[y(k) + \sum_{i=1}^P a_i y(k-i) \right]^2 \quad (2.63)$$

ce qui revient à annuler les dérivées de J par rapport au a_i : $\partial J / \partial a_i = 0$ et en posant

$r[i, j] = \sum_k y(k-i)y(k-j)$ nous obtenons :

$$\begin{bmatrix} r(1,1) & \cdot & \cdot & \cdot & \cdot & r(1,n) \\ \cdot & & & & & \cdot \\ \cdot & & & & & \cdot \\ \cdot & & & & & \cdot \\ r(n,1) & \cdot & \cdot & \cdot & \cdot & r(n,n) \end{bmatrix} \begin{bmatrix} a_1 \\ \cdot \\ \cdot \\ \cdot \\ a_n \end{bmatrix} = - \begin{bmatrix} r(1) \\ \cdot \\ \cdot \\ \cdot \\ r(n) \end{bmatrix} \quad (2.64)$$

Ceci se ramène à un système à N équations linéaires à N inconnues. Pour résoudre ce système, appelé équation de Yule-Walker, il existe plusieurs méthodes on cite, entre autres, la méthode d'autocorrélation, la méthode de covariance...etc. Nous nous intéressons, dans notre travail à la modélisation des systèmes AR et à la résolution du système d'équation d'écrit ci-dessus (calcul des coefficients du prédicteur) par filtrage en treillis.

2.5 Estimation en treillis pour la réalisation stochastique

2.5.1 Généralités

Il existe des méthodes de représentation et de modélisation des systèmes, autres que celles basées sur la fonction de transfert et sous forme de variables d'état, issues de la théorie des circuits. Dans ces méthodes la structure du filtre est considérée comme un paramètre que l'on doit pouvoir manipuler aisément. D'où la structure de filtre en cascade pour lequel l'augmentation de l'ordre laisse invariants les paramètres déjà obtenus.

De plus, ces méthodes de synthèses permettent un contrôle aisé de la stabilité du filtre obtenu. L'idée principale est que le processus x_n à modéliser est considéré comme étant la sortie d'un filtre H excité par un bruit blanc. Il existe en générale de nombreux filtres répondant à la question, mais on se restreint en pratique à rechercher le filtre H qui soit à la fois causal et à phase minimale (c.-à-d d'inverse stable). Un tel filtre, lorsqu'il existe, est unique. H est alors le filtre modélisateur de x_n et son inverse H^{-1} est appelé filtre blanchisseur car, attaqué par les observations, il produit le processus d'innovation u_n qui est un bruit blanc.

Si l'information au second ordre est fourni sous la forme d'une matrice de covariance (généralement c'est une matrice de Toeplitz cas de prédiction linéaire), le filtre blanchisseur produisant l'innovation u_n ou erreur de prédiction, s'obtient en minimisant l'erreur quadratique moyenne de prédiction par rapport aux coefficients (matriciels) de covariance. En écrivant que l'innovation obtenue est blanche, on est conduit aux équations de Yule-Walker. Dans le cas stationnaire, ceci correspond à la factorisation d'une matrice de covariance (Toeplitz) en facteur triangulaire. L'utilisation d'une structure en treillis présente, entre autres, les avantages suivants:

- Possibilité d'une double récursivité (ordre/temps).
- Mise en œuvre à l'aide des circuits intégrés VLSI.
- Stabilité facile à assurer.
- Peu sensible aux bruits de quantification.
- Rapidité de convergence.

2.5.2 Prédicteur en treillis optimal

La structure du filtre optimal, que nous allons chercher à identifier à partir des observations du signal x_n (figure 2.2), est résumée dans les relations (2.65) ci-dessous: nous avons noté avec une * les valeurs optimales des coefficients de réflexion ou de corrélation

partielle (PARCOR) K_i et des erreurs de prédictions E_i , afin de les distinguer des paramètres variables quelconques que nous utiliserons pendant la phase d'optimisation.

$$r_i(n) = r_{i-1}(n-1) - k_i^* e_{i-1}(n)$$

$$k_i^* = \frac{E[e_{i-1}(n)r_{i-1}(n-1)]}{E_{i-1}^*} = \text{cov}[e_{i-1}(n)r_{i-1}(n-1)] \quad (2.65)$$

$$E_i^* = E[e_i(n)^2] = (1 - k_i^*)E_{i-1}^*$$

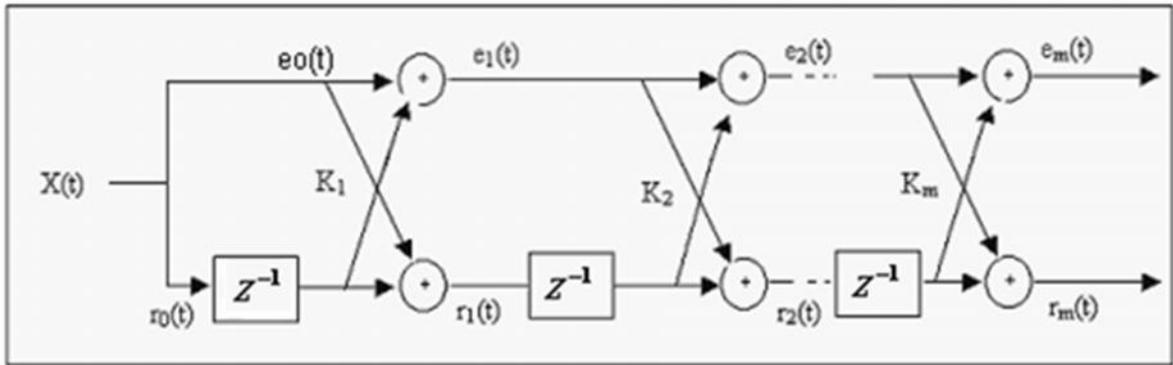


Figure 2.3 Structure en treillis d'un filtre transversal.

Dans le cas d'une réalisation des filtres type RII purement récursif conduit à une structure duale, représentée sur la figure 2.3 ci-dessous :

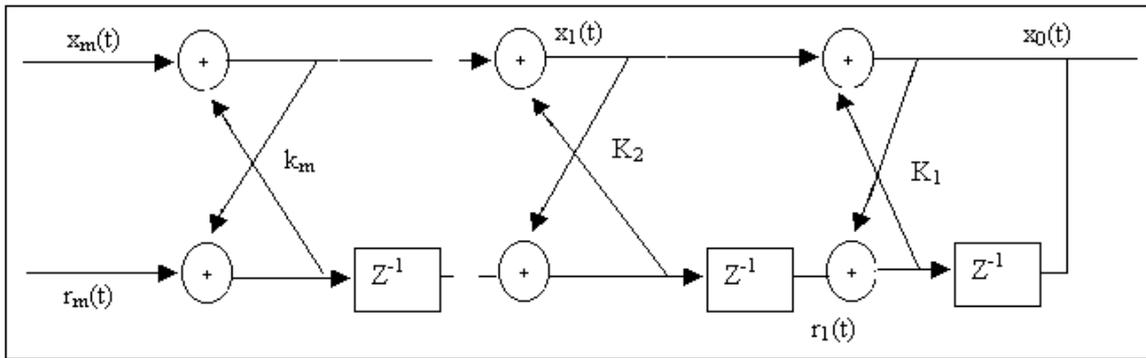


Figure 2.4 Structure en treillis d'un filtre en RII.

Notre but est de résoudre le problème de la modélisation AR du signal $x(n)$ à partir de la représentation en treillis: ceci revient à identifier les coefficients de réflexions $K_M^* = (K_1^*, \dots, K_M^*)$ du treillis optimal (2.65). Les algorithmes que nous avons utilisés pour identifier ces coefficients sont respectivement l'algorithme de Burg, l'algorithme de Shure et l'algorithme de Livinson.

2.6 Analyse Spectrale Haute Résolution

L'analyse spectrale, secteur d'activité classique en traitement du signal, n'en demeure pas moins un domaine complexe et très ouvert. Les méthodes, dites à haute résolution (*HR*) fréquentielle, restent en pratique largement sous-employées par rapport aux méthodes plus classiques qui reposent essentiellement sur le calcul de la transformée de Fourier. Les principaux obstacles à l'utilisation plus large des méthodes *HR* sont essentiellement liés au choix des paramètres libres (en particulier le nombre de composantes ou l'ordre du modèle) et à la dégradation des performances de ce type de méthodes en présence de signaux complexes (grand nombre de composantes très proches et d'amplitudes très différentes) [13, 14].

2.7 Méthode de Prony

La méthode de Prony est dédiée à l'estimation d'une somme de M sinusoides de fréquences f_k à partir d'observation non bruitée. Le processus de test à analyser est constitué avec une somme de M sinusoides données par l'équation ci-dessous [15]:

$$x_n = x(n\Delta t) = \sum_{i=1}^M A_i \cos(2ff_i n\Delta t + \theta_i) = \sum_{i=1}^M A_i \frac{\exp(j\theta_i)}{2} Z_i^n + \sum_{i=1}^M A_i \frac{\exp(-j\theta_i)}{2} Z_i^{-n} \quad (2.66)$$

$$\begin{aligned} &= \sum_{i=1}^M \frac{A_i}{2} \exp(j(2ff_i n\Delta t + \theta_i)) + \frac{A_i}{2} \exp(-j(2ff_i n\Delta t + \theta_i)) \\ &= \sum_{i=1}^M \frac{A_i}{2} \exp(j\theta_i) \exp(j2ff_i n\Delta t) + \frac{A_i}{2} \exp(-j\theta_i) \exp(-j2ff_i n\Delta t) \\ &= \sum_{i=1}^M [C_i Z_i^n + C_i^* Z_i^{*n}] \end{aligned} \quad (2.67)$$

Où :

$$C_i = \frac{A_i}{2} \exp(j\theta_i), Z_i = \exp(j2ff_i \Delta t) \quad (2.68)$$

Nous remarquons que les (Z_i) sont les racines de $x(n)$ qui définissent le polynôme

$$\Psi(Z) = \prod_{i=1}^M (Z - Z_i)(Z - Z_i^*) = \sum_{i=0}^{2M} a_i Z^{2M-i} \quad \text{avec : } a_0 = 1 \quad (2.69)$$

D'après l'hypothèse de départ sur $x(n)$ nous avons :

$$x(n-m) = \sum_{i=1}^M C_i Z_i^{n-m} + \sum_{i=1}^M C_i^* Z_i^{*(n-m)} \quad (2.70)$$

En multipliant cette équation par a_m et en effectuant une sommation sur m il vient :

$$\sum_{m=0}^M a_m x(n-m) = \sum_{m=0}^M a_m \left(\sum_{i=1}^M C_i Z_i^{n-m} + \sum_{i=1}^M C_i^* Z_i^{-(n-m)} \right) \quad (2.71)$$

Ou encore :

$$\sum_{m=0}^M a_m x(n-m) = \sum_{i=1}^M C_i Z_i^{n-M} \sum_{m=0}^M a_m Z_i^{M-m} + \sum_{i=1}^M C_i^* Z_i^{-(n-M)} \sum_{m=0}^M a_m Z_i^{-(M-m)} \quad (2.72)$$

Or : $\sum_{m=0}^M a_m Z_i^{M-m} = 0$ par définition des coefficients a_m du polynôme $\Psi(Z)$ dont les racines sont

Les Z_i d'où :

$$\sum_{m=0}^M a_m x(n-m) = 0 \quad (2.73)$$

Et donc :

$$x(n) = -\sum_{m=1}^M a_m x(n-m) \quad (2.74)$$

Les coefficients a_m pouvant donc être obtenus par la résolution du système linéaire de dimension M suivant :

$$\begin{bmatrix} x(M+1) \\ \cdot \\ x(2M) \end{bmatrix} = \begin{bmatrix} x(M) \dots \dots \dots x(1) \\ x(M+1) \dots \dots \dots x(2) \\ \cdot \\ x(2M) \dots \dots \dots x(M) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \cdot \\ a_M \end{bmatrix} \quad (2.75)$$

A partir de N coefficients a_m il est possible de former le polynôme :

$$\Psi(Z) = \sum_{m=0}^M a_m Z^{M-m} \quad \text{avec : } a_0 = 0 \quad (2.76)$$

et d'en extraire les racines complexes; Nous pouvons déterminer les fréquences f_m .

Les amplitudes respectives C_m des différentes sinusoïdes peuvent enfin être obtenues en résolvant le système linéaire suivant :

$$\begin{bmatrix} 1 & \dots & 1 & \dots & \dots & \dots & 1 \\ Z_1 & \dots & Z_2 & \dots & \dots & \dots & Z_M \\ & & & & & & \\ & & & & & & \\ & & & & & & \\ & & & & & & \\ & & & & & & \\ & & & & & & \\ & & & & & & \\ & & & & & & \\ & & & & & & \\ Z_1^{M-1} & \dots & Z_2^{M-1} & \dots & \dots & \dots & Z_M^{M-1} \end{bmatrix} \begin{bmatrix} C_1 \\ C_2 \\ \cdot \\ C_M \end{bmatrix} = \begin{bmatrix} x_0 \\ x_1 \\ \cdot \\ x_{M-1} \end{bmatrix} \tag{2.77}$$

Pour cette méthode il faut donc :

- Observer $2N$ valeur du signal $x(nT_e)$;
- Résoudre un système linéaire complexe de dimension N ;
- Extraire les racines d'un polynôme complexe de degré N ;
- Et si l'on veut les amplitudes résoudre un système linéaire complexe de dimension N ;

2.8 Méthode de Pisarenko

La méthode de Pisarenko est basée directement sur les relations entre les entrées sorties du modèle et sur les propriétés de la matrice d'autocorrélation [16, 17]. Dans cette méthode le signal $x(n)$ est supposé constitué d'une somme de N sinusoïdes $s(n)$ et d'un bruit blanc additif $b(n)$ avec :

$$x(n) = s(n) + b(n) \tag{2.78}$$

Sachant que toute sinusoïde pure $\sin(nw)$ peut s'écrire

$$\sin(nw) = 2 \cos w \sin(n-1)w - \sin(n-2)w \tag{2.79}$$

Il est possible d'écrire

$$\begin{aligned} s(n) &= -\sum_{m=1}^{2N} a_m s(n-m) \\ x(n) &= -\sum_{m=1}^{2N} a_m s(n-m) + b(n) \end{aligned} \tag{2.80}$$

En remplaçant $s(n-m)$ par $x(n-m) - b(n-m)$ il vient :

$$x(n) - b(n) = -\left(\sum_{m=1}^{2N} a_m x(n-m) - \sum_{m=1}^{2N} a_m b(n-m)\right) \tag{2.81}$$

$$\sum_{m=0}^{2N} a_m x(n-m) = \sum_{m=0}^{2N} a_m b(n-m) \tag{2.82}$$

Ce qui peut s'écrire matriciellement :

$$\begin{aligned} X^T(n)A &= B^T(n)A \\ \text{avec :} \\ X^T(n) &= [x(n), x(n-1), \dots, x(n-2N)]^T \\ B^T(n) &= [b(n), b(n-1), \dots, b(n-2N)]^T \end{aligned} \tag{2.83}$$

Et

$$A = \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ \vdots \\ \vdots \\ a_{2N} \end{bmatrix}$$

En multipliant l'équation (II.83) par $X(n)$ d'où

$$[X(n)X(n)^T]A = [X(n)B(n)^T]A \tag{2.84}$$

Et en prenant l'espérance on obtient

$$\begin{aligned} E[X(n)X(n)^T]A &= E[X(n)B(n)^T]A \\ E[X(n)X(n)^T]A &= E[(S(n) + B(n))B(n)^T]A \\ E[X(n)X(n)^T]A &= E[S(n)B(n)^T + B(n)B(n)^T]A \end{aligned} \tag{2.85}$$

Or le bruit est supposé blanc de variance σ^2 et décorrélé du mélange de sinusoides, cette équation devient donc :

$$\begin{aligned} E[X(n)X(n)^T]A &= E[(S(n) + B(n))B(n)^T]A = (E[S(n)B(n)^T] + E[B(n)B(n)^T])A \\ R_{2N+1}A &= E[S(n)]E[B(n)^T] + \sigma^2 IA \\ R_{2N+1}A &= \sigma^2 A \end{aligned} \tag{2.86}$$

Le vecteur A est donc le vecteur propre associé à la valeur propre σ^2 avec la contrainte, ayant le vecteur A , nous pouvons écrire la transformée en Z de l'équation :

$$s(n) = \sum_{m=1}^{2N} a_m s(n-m) \tag{2.87}$$

Sous la forme :

$$S(Z) \left(1 - \sum_{m=1}^{2N} a_m Z^{-m} \right) = 0 \tag{2.88}$$

Les valeurs de Z pour lesquelles cette équation est vérifiée donnent les valeurs des fréquences présentes dans le mélange; il faut donc extraire les racines du polynôme

$$1 - \sum_{m=1}^{2N} a_m Z^{-m} \text{ pour obtenir les } N \text{ valeurs des fréquences.}$$

Si N et 2 ne sont pas connus a priori il suffit de surdimensionner la matrice R et d'analyser ses valeurs propres. En effet, il est possible d'obtenir les puissances des sinusoïdes détectées ; si nous procédons comme suit :

Premièrement nous avons dans le cas de deux sinusoïdes :

$$\begin{aligned} s(n) &= A_1 \cos sw_1 + A_2 \cos sw_2 \\ r(n) &= E[s(n)s(n+\ddagger)] \\ r(n) &= E[(A_1 \cos w_1 + A_2 \cos w_2)(A_1 \cos w_1(t+\ddagger) + A_2 \cos w_2(t+\ddagger))] \\ r(n) &= A_1^2 E[\cos w_1 \cos w_1(t+\ddagger)] + A_1 A_2 E[\cos w_1 \cos w_2(t+\ddagger)] + \\ &A_2 A_1 E[\cos w_2 \cos w_1(t+\ddagger)] + A_2^2 E[\cos w_2 \cos w_2(t+\ddagger)] \end{aligned} \tag{2.89}$$

$$r(n) = \frac{A_1^2}{2} \cos w_1 \ddagger + \frac{A_2^2}{2} \cos w_2 \ddagger \tag{2.90}$$

Donc pour N sinusoïdes on a :

$$\begin{aligned} \ddagger = 1, r(1) &= P_1 \cos w_1 + P_2 \cos w_2 + \dots + P_n \cos w_n \\ \ddagger = 2, r(2) &= P_1 \cos 2w_1 + P_2 \cos 2w_2 + \dots + P_n \cos 2w_n \\ \dots &\dots \dots \dots \dots \dots \dots \dots \dots \\ \dots &\dots \dots \dots \dots \dots \dots \dots \dots \\ \dots &\dots \dots \dots \dots \dots \dots \dots \dots \\ \dots &\dots \dots \dots \dots \dots \dots \dots \dots \\ \ddagger = n, r(n) &= P_1 \cos nw_1 + P_2 \cos nw_2 + \dots + P_n \cos nw_n \end{aligned} \tag{2.91}$$

Où $P_n = \frac{A_n^2}{2}$ est la puissance moyenne de la $n^{\text{ème}}$ sinusoïde d'amplitude A_n ; cependant; nous pouvons obtenir la forme matricielle suivante :

$$\begin{bmatrix} \cos w_1 \dots \cos w_2 \dots \dots \dots \cos w_n \\ \cos 2w_1 \dots \cos 2w_2 \dots \dots \dots \cos 2w_n \\ \dots \\ \dots \\ \dots \\ \dots \\ \dots \\ \cos nw_1 \dots \dots \dots \cos nw_n \end{bmatrix} \begin{bmatrix} P_1 \\ P_2 \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ P_n \end{bmatrix} = \begin{bmatrix} r(1) \\ r(2) \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ r(n) \end{bmatrix} \tag{2.92}$$

Disposant des pulsations w_i et des coefficients d'autocorrélation $r(i)$; il suffit de résoudre ce système pour trouver les puissances respectives P_i des raies spectrales identifiées.

En conclusion pour analyser un signal selon la méthode de Pisarenko il faut :

- Observer N valeurs du signal $x(nT_e)$;
- Calculer la matrice d'autocorrélation et faire la décomposition en éléments propres ;
- Détecter la variance λ^2 correspondant à la valeur propre minimale de la matrice d'autocorrélation ;
- Extraire les racines d'un polynôme complexe de degré $2N$
- Enfin si nous voulons les puissances, résoudre un système réel de N équations à N inconnues ;

La décomposition en éléments propres reste pour l'instant l'étape la plus délicate à réaliser de manière rapide ce qui constitue un frein principal pour utiliser cette méthode.

2.9 Conclusion

Les méthodes dites haute résolution sont très compétitives, elles peuvent explorer le contenu fréquentiel de notre système. L'information pertinente que nous envisageons est considérée comme une pollution fréquentielle. Cette pollution se situe au voisinage de la fréquence principale. Les méthodes classiques sont incapables d'extraire ces fréquences caractéristiques, c'est la raison pour laquelle nous avons opté pour les méthodes hautes résolution.

2.10 Références bibliographiques

[1] M. Kunt et al., *Techniques Moderne de Traitement Numérique du Signal*, Collection Electricité : Traitement de l'Information, vol. 1, Ed. Polytechniques, 1991.

- [2] Michel Terre, *Traitement numérique du signal*, Ecole Nation. Super. de Techniques Avancées ENSTA ES101, Version 3.2 janvier 2003.
- [3] N. Moreau, *Modélisation, Estimation Spectrale*, Ed. Télécom, Paris, 1990.
- [4] J. Fryer, M. E. Odegard & G. H. Sutton, *Deconvolution and Spectral Estimation Using Final Prediction Error*, *Geophys.*, vol. 40, pp. 411-425, June 1975.
- [5] W. Gersch & D. R. Sharpe, *Estimation of Power Spectra with Finite-Order Autoregressive Models*, *IEEE Trans. Automat. Contr.*, vol. AC-18, pp. 367-369, Aug. 1973.
- [6] R. H. Jones, *Autoregressive Order Selection*, *Geophys.*, vol.41, pp. 771-773, Aug. 1976.
- [7] T. J. Ulrych & T. N. Bishop, *Maximum Entropy Spectral Analysis and Autoregressive Decomposition*, *Rev. Geophysics Space Phys.*, vol. 13, pp. 183-200, Feb. 1975.
- [8] R. L. Kashyap, *Inconsistency of the AIC Rule for Estimating the Order of Autoregressive Models*, *IEEE Trans. Automat. Contr.*, vol. AC-25, pp. 996-998, Oct. 1980.
- [9] M. Pagano, *Estimation of Models of Autoregressive Signal plus White Noise*, *Ann. Statistics*, vol. 2, pp. 99-108, 1974.
- [10] S. L. Marple, Jr., *Conventional Fourier Autoregressive and Special ARMA Methods of Spectrum Analysis*, Engineer's Dissertation, Stanford Univ., Stanford, CA, Dec. 1976.
- [11] R. J. Keeler, *Uncertainties in Adaptive Maximum Entropy Frequency Estimators*, NOAA Tech. Rep. ERL-105-WPL53, Feb. 1979 (Order NTIS No. N 79-32489).
- [12] H. Sakai, *Statistical Properties of AR Spectral Analysis*, *IEEE trans. Acous. Sp. & Sign. Proc.*, vol. ASSP-27, pp. 402-409, Aug. 1979.
- [13] J. P. Toomey, *High Resolution Frequency Measurement by linear Prediction*, *IEEE Trans. Aerospace Electron. Syst.*, vol. AES-16, pp. 517-525, July 1980.
- [14] S. L. Marple, Jr., *Frequency Resolution of High-Resolution Spectrum Analysis Techniques*, In Proc. 1978 RADC Spectrum Estimation Workshop, pp. 19-35.
- [15] Ta-Hsin Li and Benjamin Kedem, *Improving prony's for multiple frequency estimation by a general method of parametric filtering*, Department of mathematics and institute for systems research. University of Maryland, college Park, MD 20742 USA. IEEE, 1993.
- [16] V.F.Pisarenko, *The retrieval of harmonics from a covariance Function*, *Geophysics Journal of the Royal Astronomical Society*, vol.33, pp347-366, 1973.
- [17] K. Dachoon and Winsler E. Alxander, *The Modified Pisarenko's Algorithm for Adaptative Spectrum Estimation*, CH2633-6/88/0000-0081 \$1.00, IEEE, 1988.

3. Chapitre 3 : Les Réseaux d'Ondelettes et l'Analyse en Composants Principales (ACP)

3.1 Introduction

Le terme *ondelette* désigne une fonction qui oscille pendant un “ temps donné” (si la variable est le temps) ou sur un intervalle de longueur finie (si la variable est de type spatial). Au-delà, la fonction décroît très vite vers zéro.

Historiquement, les premières ondelettes (introduites par Haar dans les années 1930) constituaient une base de fonctions orthogonales. Les ondelettes de Haar présentent la particularité de ne pas être dérivables.

Plus récemment, de nouvelles fonctions ondelettes ont été introduites, Meyer 85 et Meyer 90, qui constituent également une base de fonctions orthogonales, et qui, de plus, sont dérivables. Elles ont été notamment mises en œuvre dans le cadre de l'analyse multirésolution de signaux. Ces ondelettes ne peuvent s'exprimer sous une forme analytique simple. Pour cette raison, elles sont peu adaptées pour l'approximation de fonctions. Les structures obliques (*frames* en anglais) ont été introduites par J. Morlet dans le but de trouver des bases de fonctions (non nécessairement orthogonales) pour représenter des signaux. Ces structures obliques ont été ensuite l'objet des travaux de Daubechies [Daubechies90] qui a développé un support théorique aux résultats de J. Morlet. Les structures obliques ont des expressions analytiques simples, et toute fonction de carré sommable peut être approchée, avec la précision voulue, par une somme finie d'ondelettes issues d'une structure oblique.

Qu'y a-t-il de commun entre le stockage numérique des empreintes digitales effectué par le FBI, la compression des images pour la télévision haute définition et le téléphone vidéo, le stockage ou la transmission de résultats de mesures sismiques, l'analyse des grandes structures galactiques, la modélisation des cascades d'énergie dans des écoulements hydrodynamiques fortement turbulents, ou encore la détection des ondes gravitationnelles? Fondamentalement rien, si ce n'est que tous ces problèmes (et bien d'autres encore) sont susceptibles d'être attaqués en utilisant une famille de méthodes, génériquement appelées méthodes temps-fréquence, et en particulier l'analyse par ondelettes.

L'analyse par ondelettes a été introduite au début des années 1980, dans un contexte d'analyse du signal et d'exploration pétrolière. Il s'agissait à l'époque de donner une représentation des signaux permettant de faire apparaître simultanément des informations temporelles (localisation dans le temps, durée) et fréquentielles, facilitant par-là

l'identification des caractéristiques physiques de la source du signal. Les ondelettes n'ont depuis lors cessé de se développer et de trouver de nouveaux champs d'application. Avec quelques années de recul, nous réalisons maintenant que ce sont ces origines «scientifiquement cosmopolites» qui ont donné à la théorie toute sa richesse et sa beauté, en même temps que ses vastes domaines d'application [1, 2, 3, 4, 5, 6, 7].

Nous abordons les définitions et les propriétés dans les cas continu et discret. Nous présenterons succinctement les concepts d'analyse multirésolution et codage en sous bandes.

3.2 Les Ondelettes dans le cas Continu

Une transformée en ondelettes est dite continue lorsque les paramètres structurels des fonctions utilisées (c'est-à-dire les translations et les dilatations) peuvent prendre n'importe quelle valeur de l'ensemble des réels R (les dilatations doivent néanmoins être positives).

Fondamentalement, la transformée en ondelettes se calcule de la même façon que la transformée de Fourier fenêtrée (SFT : Short Fourier Transform) : on regarde la corrélation, ou le produit scalaire sur $L^2(\mathbb{R})$ entre le signal à analyser et une famille de fonctions bien localisées $\{\mathbb{E}_{s,u}(t), s \in \mathfrak{R}_+, u \in \mathfrak{R}\}$ en temps et fréquence [1, 2, 3]:

$$TO_x(s, u) = \langle x, \mathbb{E}_{s,u} \rangle = \int_{\mathfrak{R}} x(t) \mathbb{E}_{s,u}^*(t) dt \quad (3.1)$$

Les coefficients $TO_x(s, u)$ s'interprètent comme la projection du signal $x(t)$ sur la famille $\{\mathbb{E}_{s,u}(t)\}$ des fonction obtenues par dilatation de s et translation de u et de l'ondelette mère

$$\mathbb{E} : \quad \mathbb{E}_{s,u}(t) = \frac{1}{\sqrt{s}} \mathbb{E}\left(\frac{t-u}{s}\right) \quad (3.2)$$

Le facteur $\frac{1}{\sqrt{s}}$ normalise $\mathbb{E}_{s,u}$ afin de préserver l'énergie du motif analysant :

$$\|\mathbb{E}_{s,u}\|_2^2 = \int_{\mathfrak{R}} |\mathbb{E}_{s,u}(t)|^2 dt = 1 \quad (3.3)$$

La transformée en ondelettes est une représentation covariante par changement d'échelle et translation en temps c'est-à-dire qu'elle vérifie :

$$y(t) = \sqrt{s_0} x(s_0(t - u_0)) \rightarrow TO_y\left(\frac{s}{s_0}, s_0(u - u_0)\right) \quad (3.4)$$

Le signal peut être reconstruit à partir de ses coefficients en ondelette sous réserve que l'ondelette \mathbb{E} vérifie la condition d'admissibilité, c'est-à-dire que l'intégrale suivant existe et soit finie :

$$C_{\mathbb{E}} = \int_a^{+\infty} \frac{|\hat{\mathbb{E}}(v)|^2}{|v|} dv < +\infty \quad (3.5)$$

où $\hat{\mathbb{E}}(v)$ désigne la transformée de Fourier de $\mathbb{E}(t)$. La formule de reconstruction fait intervenir ce coefficient de normalisation $C_{\mathbb{E}}$:

$$x(t) = \frac{1}{C_{\mathbb{E}}} \int_{u \in \mathfrak{R}} \int_{s>0} TO_x(s, u) \frac{1}{\sqrt{s}} \mathbb{E}\left(\frac{t-u}{s}\right) du \frac{ds}{s^2} \quad (3.6)$$

Pour garantir l'existence finie de $C_{\mathbb{E}}$, il faut s'assurer de la convergence de l'intégrale aux bornes. A l'infini il faut que le spectre de l'ondelette mère ait une décroissance au moins en $|v|^{-1/2}$. Par contre autour de l'origine, le spectre doit s'annuler pour assurer la convergence de l'intégrale en zéro :

$$\mathbb{E}^{\wedge}(0) = \int_{-\infty}^{+\infty} \mathbb{E}(t) dt = 0 \quad (3.7)$$

Cette condition impose à l'ondelette d'être à moyenne nulle. Ainsi, son amplitude passe forcément par 0 et présente donc quelques oscillations d'où son nom.

L'analyse par les ondelettes conserve également les identités classiques (Parseval, Plancherel). La formule de Plancherel permet d'écrire que :

$$E_x = \int_{-\infty}^{+\infty} |x(t)|^2 dt = \int_{-\infty}^{+\infty} \int_0^{+\infty} \frac{1}{C_{\mathbb{E}}} |TO_x(s, u)|^2 du \frac{ds}{s^2} \quad (3.8)$$

Dans cette formule apparaît une grandeur importante : $|TO_x(s, u)|^2$ que l'on nomme scalogramme c'est cette grandeur que l'on représente généralement dans le demi-plan Temps-fréquence parce qu'elle traduit la manière dont l'énergie E_x du signal s'y répartit. Finalement, l'approche fréquentielle permet la réécriture de l'équation :

$$TO_x(s, u) = \int_{\mathfrak{R}} x(t) \mathbb{E}^*\left(\frac{t-u}{s}\right) dt = \int_{-\infty}^{+\infty} X(v) \Psi^*(sv) e^{2ifvu} \sqrt{s} dv . \quad (3.9)$$

Cette formule conduit à une interprétation plus physique des coefficients d'ondelettes qu'on peut percevoir comme la série temporelle d'un banc de filtres. Chaque filtre du banc est dit un filtre unique par un changement d'échelle.

3.3 Les Ondelettes dans le cas discret

La transformée en ondelettes continue est très redondante. Il suffit en pratique de quelques coefficients pour couvrir entièrement le plan temps-échelle.

On discrétise ainsi la représentation continue en échantillonnant à la fois le paramètre d'échelle s et le paramètre de translation temporelle u , un échantillonnage judicieux de ces grandeurs doit [8, 9] :

- garantir la reconstruction du signal analysé, en trouvant un juste compromis entre la redondance et la perte d'information.
- Utiliser au mieux les caractéristiques propres aux fonctions analysantes $\mathbb{E}_{s,u}$ et aux signaux que l'on désire étudier.

C'est pourquoi on choisit un échantillonnage logarithmiquement uniforme des paramètres et non pas un échantillonnage linéaire. La grille d'échantillonnage est la suivante :

$$\{(s, u) = (s_0^m, nu_0 s_0^m); s_0 > 0, u_0 > 0; n, m \in \mathbb{Z}\}$$

où m et n représentent les indices d'échelle et de temps respectivement.

La transformée en ondelettes discrète se formalise comme suit :

$$TO_{m,n}(x) = s_0^{-m/2} \int_{-\infty}^{+\infty} x(t) \mathbb{E}^*(s_0^{-m} t - nu_0) dt; n, m \in \mathbb{Z}$$

Et la formule de reconstruction s'écrit :

$$x(t) = \sum_m \sum_n \langle x, \mathbb{E}_{m,n}^* \rangle \mathbb{E}_{m,n}(t) = \sum_m \sum_n TO_{m,n}(x) \mathbb{E}_{m,n}(t) \quad (3.10)$$

On choisit fréquemment les valeurs $s_0 = 2$ et $u_0 = 1$, ce qui conduit à une échelle logarithmique formant un réseau appelé réseau dyadique ou une représentation octave par octave.

Un tel échantillonnage permet de construire des bases orthonormées associées à des ondelettes bien localisées en temps et en fréquence ($u_0 < 1$ entraîne des recouvrements tandis que $u_0 > 1$ conduit à un sous échantillonnage).

La famille $\{\mathbb{E}_{m,n}(t) = 2^{-m/2} \mathbb{E}(2^{-m} t - n), (m, n) \in (\mathbb{Z}, \mathbb{Z})\}$, constitue alors une base (non nécessairement orthonormale) multirésolution de $L^2(\mathfrak{R})$. Nous reviendrons sur ces notions ci-après.

3.4 Quelques exemples d'ondelettes

Montrons maintenant quelques exemples d'ondelettes à titre indicatif.

3.4.1 L'Ondelette de Morlet

La première ondelette est l'ondelette de Morlet. C'est l'une des ondelettes les plus utilisées pour l'analyse et l'interprétation des signaux car elle possède une forme analytique simple et est une bonne résolution en temps et en fréquence. En effet son enveloppe est gaussienne donc la borne du principe d'incertitude est atteinte. Elle est régulière, Elle présente par contre l'inconvénient d'un support non compact. Elle n'est pas orthogonale donc ne peut être utilisée pour le codage. De plus, son spectre n'est pas tout à fait nul à l'origine ce qui empêche une parfaite reconstruction du signal à partir de ses coefficients en ondelette. Son expression est celle d'une gaussienne modulée :

$$\mathbb{E}(t) = e^{ict} \cdot e^{-\frac{t^2}{2}} - \sqrt{2} e^{ict} \cdot e^{-c^2 e^{-t^2}} \quad (3.11)$$

pour rendre l'ondelette admissible, on choisit c suffisamment grand ($c > 3.3$) ce qui permet de s'affranchir du second paramètre.

3.4.2 L'ondelette Gaussian Chirp

On peut construire une autre ondelette, très proche de la première mais dont la fréquence instantanée varie cette fois linéairement avec le temps t . Surnommée 'Gaussian Chirp' elle s'écrit :

$$\mathbb{E}(t) = e^{ict} e^{ikt^2/2} e^{-\frac{t^2}{2}} \quad (3.12)$$

- $k > 0$ et c est fixe, la valeur définie dans le cas l'ondelette de Morlet.

3.4.3 L'ondelette de chapeau Mexicain

Il existe l'ondelette « chapeau Mexicain » qui est la dérivée seconde de la gaussienne :

$$\mathbb{E}(t) = (1 - t^2) e^{-\frac{t^2}{2}} \quad (3.13)$$

Toutes ces ondelettes s'obtiennent à partir des gaussiennes, car elles réalisent la qualité dans le principe d'incertitude de Gabor-Heisenberg, donc elles offrent la meilleure localisation conjointe en temps et en fréquence.

3.4.4 L'ondelette de Haar

L'ondelette de Haar a été introduite historiquement par Haar5 en 1910. C'est une fonction en escalier bipolaire :

$$h(t) = \begin{cases} 1 & \text{pour } 0 < t < \frac{1}{2} \\ -1 & \text{pour } \frac{1}{2} < t < 1 \\ 0 & \text{sin on} \end{cases} \quad (3.14)$$

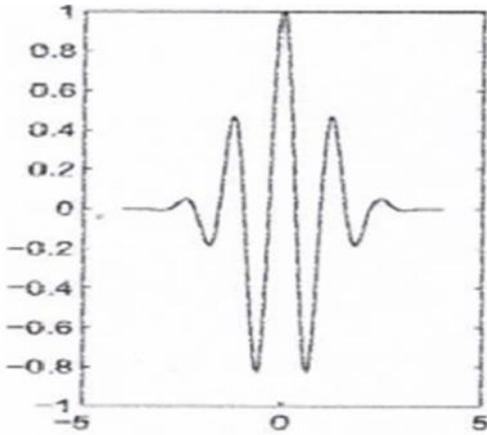


Figure 3.1 Ondelette de Morlet

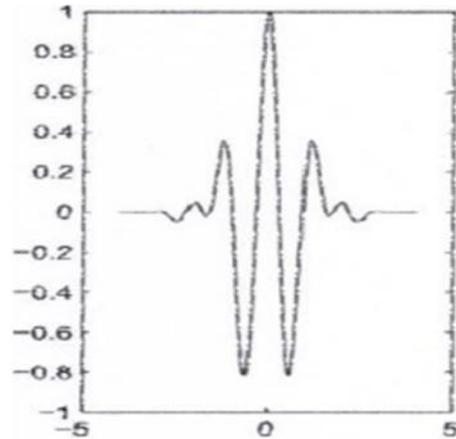


Figure 3.2 Ondelette Gaussian Chirp (k=1)

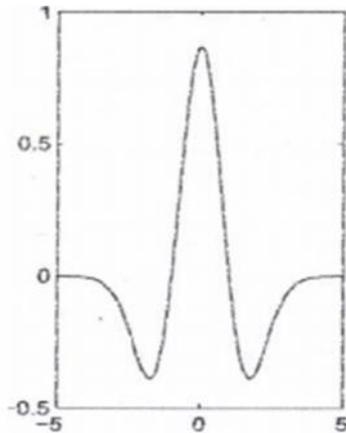


Figure 3.3 Ondelette de chapeau Mexicain

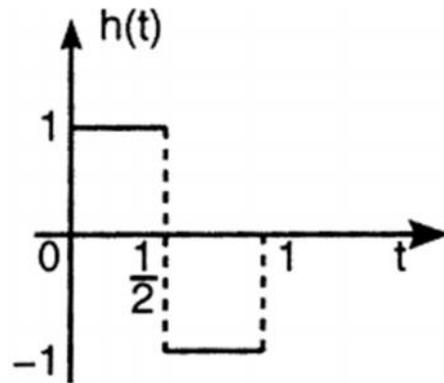


Figure 3.4 Ondelette de Haar

3.5 Analyse Multirésolution

L'analyse multirésolution (AMR) est un formalisme mathématique qui permet de construire aisément des bases orthonormées d'ondelettes. Le principe consiste à décomposer

le signal à analyser en une suite de coefficients d'approximation et de détail, chaque suite d'approximation se décompose à nouveau en approximation plus détaillée.

A chaque itération de cette décomposition, les coefficients de détail correspondent aux coefficients en ondelette du signal à une échelle donnée [1, 2].

3.3.1 Définition

On appelle analyse multirésolution toute suite $(V_j)_{j \in \mathbb{Z}}$ décroissante de sous-espaces emboîtés : $\dots V_1 \subset V_0 \subset V_1 \dots$ de $L^2(\mathfrak{R})$ qui vérifie les propriétés suivantes :

- (i) l'intersection des V_j est nulle soit $\bigcap_{j=-\infty}^{+\infty} V_j = \{0\}$.
- (ii) L'union des V_j est dense dans $L^2(\mathfrak{R})$ soit $\bigcup_{j=-\infty}^{+\infty} V_j = L^2(\mathfrak{R})$.
- (iii) $x(t)$ est dans V_j si et seulement si sa version contractée par un facteur de 2 est dans :
 V_{j-1} c'est-à-dire $x(t) \in V_j \Leftrightarrow x(2t) \in V_{j-1} \Leftrightarrow x(2^j t) \in V_0$.
- (iv) si $x(t)$ est dans V_j , ses translations 'entières' sont dans :
 $V_j, x(t) \in V_j \Leftrightarrow x(t-k) \in V_j, \forall k \in \mathbb{Z}$.
- (v) il existe une fonction $w(t)$ de V_0 , telle que la famille $\{w(t-k); k \in \mathbb{Z}\}$ est une base orthonormée de V_0 .

Les espaces V_j constituent des espaces d'approximation. La projection d'une fonction $x(t)$ de $L^2(\mathfrak{R})$ sur le sous-espace V_j constitue une approximation de $x(t)$ à l'échelle 2^j . La condition (iii) assure que toute fonction de $L^2(\mathfrak{R})$ peut-être approchée dans cette analyse.

La dernière condition implique qu'une base orthonormée de V_j peut se déduire de la base de V_0 à partir d'une seule fonction $w(t)$ appelée fonction d'échelle, en construisant la famille :

$$w_{j,k}(t) = 2^{-j/2} w(2^{-j}t + k), k \in \mathbb{Z}. \quad (3.15)$$

Ceci implique encore que :

$$w_{j,k}(t) = 2^{-j/2} w(2^{-j}t + k), j \in \mathbb{Z}, k \in \mathbb{Z} \quad (3.16)$$

est une base orthonormée de $\bigcup_j V_j = L^2(\mathfrak{R})$. On adopte la convention d'indexation de Daubechies pour l'AMR : $V_j \rightarrow L^2(\mathfrak{R})$ quand $j \rightarrow -\infty$. Dans cette convention, le signal

échantillonné appartient à V_0 et l'échelle de l'ondelette croit avec j . Quand on passe de V_j à V_{j-1} , on dilate l'ondelette d'un facteur de deux et on divise sa bande fréquentielle par deux.

Les coefficients d'approximation au niveau de résolution j sont obtenus par projection du signal sur les éléments de la famille $\{w_{j,k}, j, k \in \mathbb{Z}\}$:

$$a_{j,k} = \int_{-\infty}^{+\infty} x(t) w_{j,k}(t) dt . \quad (3.17)$$

Les différences d'information entre deux résolutions successives conduit à introduire les coefficients de détail de sorte que les coefficients d'approximation à une résolution donnée se retrouvent à partir de ceux d'approximation et détail à la résolution suivante.

Si l'on attribue aux coefficients de détail un espace d'existence W_j , on aura à un niveau de résolution j :

$$V_{j-1} = V_j \oplus W_j \quad (3.18)$$

Ce qui signifie que W_j est le complémentaire orthogonal de V_j dans V_{j-1} , par construction, les W_j sont orthogonaux entre eux et leur somme directe couvre $L^2(\mathfrak{R})$:

$$L^2(\mathfrak{R}) = \bigoplus_{j=-\infty}^{+\infty} W_j \quad (3.19)$$

De façon similaire aux V_j , les W_j vérifient un certain nombre de conditions :

- (i) $\bigcap_{j=-\infty}^{+\infty} W_j = \{0\}$.
- (ii) $\bigcup_{j=-\infty}^{+\infty} W_j = L^2(\mathfrak{R})$.
- (iii) $x(t) \in W_j \Leftrightarrow x(2t) \in W_j$.
- (iv) $x(t) \in V_j \Leftrightarrow x(t-k) \in V_j, \forall k \in \mathbb{Z}$

Le problème suivant est celui de savoir si l'on dispose d'une base orthonormée dans les W_j de sorte qu'une collection :

$$\{\mathbb{E}_{j,k}(t) = 2^{-j/2} \mathbb{E}(2^{-j}t - k); (j, k) \in (\mathbb{Z}, \mathbb{Z})\} \quad (3.20)$$

constitue une base orthonormée de $L^2(\mathfrak{R})$. Pour cela, il suffit d'avoir une fonction $\mathbb{E}(t)$ de V_0 telle que la famille $\{\mathbb{E}(t-k), k \in \mathbb{Z}\}$ soit une base orthonormée de W_0 . Cette fonction sera alors appelée ondelette.

3.3.2 Fonction d'échelle

La fonction $w(t)$ est appelée fonction d'échelle. L'analyse multirésolution lui confère des propriétés intéressantes, puisque $V_0 \subset V_{-1}$, alors n'importe quelle fonction dans V_0 peut s'écrire comme combinaison linéaire des fonction de V_{-1} . On considère donc $w(t)$ dans V_0 et $w(2t - k), \forall k \in \mathbb{Z}$ dans V_{-1} , reliées selon :

$$w(t) = \sqrt{2} \sum_n h_n w(2t - n) \quad (3.21)$$

Les h_n sont les coordonnées de $w(t)$ dans la base $\{\sqrt{2}w(2t - k), k \in \mathbb{Z}\}$. Pour une base orthonormée les coordonnées vérifient :

$$h_n = \sqrt{2} \int_{-\infty}^{+\infty} w(t) w(2t - n) dt \quad \text{et} \quad \sum_{n=-\infty}^{+\infty} h_n^2 = 1. \quad (3.22)$$

On peut de la même façon que la fonction d'échelle caractériser l'ondelette $\mathbb{E}(t)$ qui est dans $W_0 \subset V_{-1}$, en introduisant le filtre discret $g(n)$ tel que :

$$\mathbb{E}(t) = \sqrt{2} \sum_n g_n w(2t - n) \quad (3.23)$$

3.6 Ondelettes et filtrage numérique

Nous avons vu que l'analyse multirésolution permettait de décomposer un signal en coefficients d'approximation et de détail, ceci à partir d'une fonction d'échelle $w(t)$ et d'une ondelette mère $\mathbb{E}(t)$ [9, 10].

En vérité, chacune de ces fonctions est estimée au moyen des séquences h_n et $g_n = (-1)^n h_{1-n}$ et il suffit de connaître les valeurs de la suite h_n pour effectuer la décomposition par AMR.

Les équations (3.22) et (3.23) peuvent s'écrire comme des relations de filtrage-décimation :

$$\begin{aligned} w(t) &= \sqrt{2} [(h * w(\cdot)) \downarrow 2] \\ \mathbb{E}(t) &= \sqrt{2} [(g * w(\cdot)) \downarrow 2] \end{aligned} \quad (3.24)$$

Le symbole \downarrow représente l'opérateur de décimation (\uparrow sera l'opérateur d'interpolation).

Si l'on reprend la définition des coefficients d'approximation et de détail, ils s'expriment à une échelle donnée j comme un produit scalaire :

$$\begin{aligned} a_{j,k} &= \langle x, W_{j,k} \rangle \\ d_{j,k} &= \langle x, \mathbb{E}_{j,k} \rangle \end{aligned} \quad (3.25)$$

On souhaite avoir les valeurs, récursivement, des coefficients d'approximation $a_{j,k}$ à l'échelle j . On a alors :

$$\begin{aligned} a_{j,k} &= \int x(t) 2^{-j/2} w(2^{-j}t - k) dt \\ &= \int x(t) 2^{-j/2} [\sqrt{2} \sum_n h_n w(2(2^{-j}t - k) - n)] dt \\ &= \sum_n h_n \int x(t) 2^{-\frac{j-1}{2}} w(2^{-j+1}t - (2k + n)) dt \\ &= \sum_n h_n a_{j-1, 2k+n} \end{aligned} \quad (3.26)$$

On voit donc que les coefficients d'approximation se calculent récursivement selon :

$$a_{j,k} = \sum_n h_{n-2k} a_{j-1,n} \quad (3.27)$$

En termes de filtrage, les coefficients d'approximation de l'échelle j s'obtiennent donc, à partir des coefficients d'approximation de l'échelle le plus fine $j+1$ par convolution puis décimation d'un facteur de 2.

Pour les coefficients détaillés, on obtient de la même façon la relation :

$$d_{j,k} = \sum_n g_{n-2k} a_{j-1,n} \quad (3.28)$$

Il se calculent également à partir des coefficients d'approximation de l'échelle j mais à travers le filtre g_n .

Notons que les filtres apparaissant dans les relation (3.27) et (3.28) sont les retournés dans le temps des filtres h_n et g_n .

On peut formaliser ces deux opérations dans la lecture suivante :

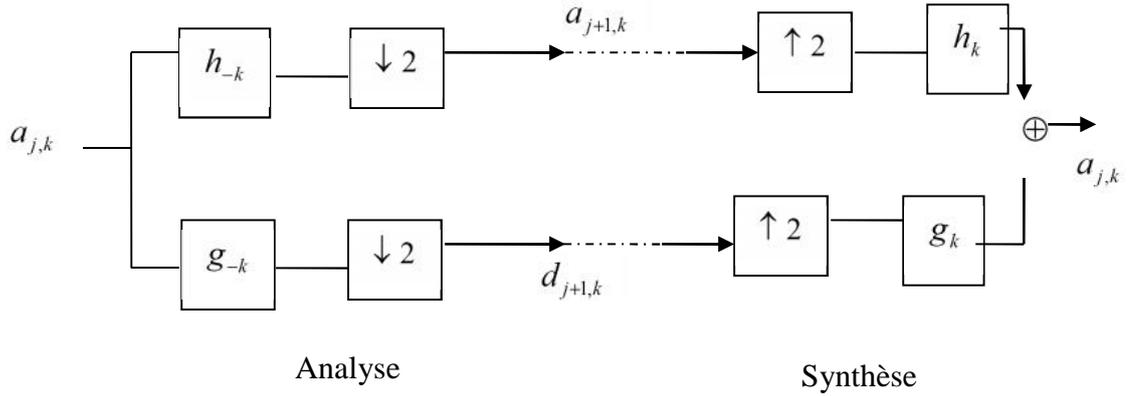


Figure 3.5 Analyse et synthèse de la transformée orthogonale en ondelettes

3.7 Algorithme de reconstruction

Nous avons vu que le sous-espace W_j est défini comme le supplément orthogonal de V_j dans V_{j-1} .

On peut donc, écrire que l'approximation $x_{j-1}(t)$, à la résolution $j-1$ du signal $x(t)$ est égale à l'approximation $x_j(t)$ à la résolution j compte tenu du signal de détail reconstruit à cette même résolution :

$$x_{j-1}(t) = x_j(t) + \sum_{k=-\infty}^{+\infty} d_{j,k} \mathbb{E}_{j,k}(t) \quad (3.29)$$

L'approximation $x_j(t)$ correspond à la projection de $x(t)$ sur les limites de V_j , donc se développe en $x_j(t) = \sum_l a_{j,l} w_{j,l}(t)$, il vient :

$$\sum_l a_{j-1,l} w_{j-1,l}(t) = \sum_l a_{j,l} w_{j,l}(t) + \sum_l d_{j,l} \mathbb{E}_{j,l}(t) \quad (3.30)$$

Finalement l'algorithme de synthèse est :

$$a_{j-1,k} = \sum_l h_{k-2l} a_{j,l} + \sum_l g_{k-2l} d_{j,l} \quad (3.31)$$

3.8 Reconnaissance et Classification

Le théorème de Parseval est appliqué pour calculer l'énergie de déformation des paquets détails que nous avons obtenu en appliquant la transformée en ondelette discrète inverse (IDWT) à chaque niveau analysé. La distribution de l'énergie de déformation est obtenue en comparant l'énergie dans le cas sain avec l'énergie dans le cas défaillant. Cette

déviations d'énergie peut être utilisée en entrée du schéma de classification à base du PNN selon l'organigramme de traitement suivant [11, 12, 13] :

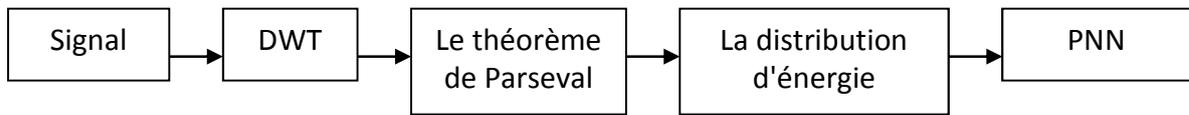


Figure 3.6 Organigramme de Traitement

3.8.1 Théorème de Parseval (Evaluation de la déviation d'énergie)

Le théorème de Parseval assume que l'énergie du signal discret $v(n)$ est égale à la somme des carrés de la transformée de Fourier du spectre dans le domaine fréquentiel :

$$\frac{1}{N} \sum_{n=\langle N \rangle} |v(n)|^2 = \sum_{h=\langle N \rangle} |V_h|^2 \quad (3.32)$$

où N est la longueur d'échantillon, V_n sont les coefficients du transformée de Fourier du spectre. En appliquant le théorème à la DWT, nous obtenons :

$$\frac{1}{N} \sum_{n=\langle N \rangle} |v(n)|^2 = \frac{1}{N_J} \sum_k |XX_{J,k}|^2 + \sum_{j=1}^J \frac{1}{N_J} \sum_k |CT_{j,k}|^2 \quad (3.33)$$

Où : XX , CT sont les coefficients d'approximation et de détail respectivement, pour lesquels la IDWT est consciencieux à chaque niveau. Le premier terme à droite de (3.33) dénote le pouvoir moyen de paquet de se rapproché au signal décomposé.

Le deuxième terme donne la distribution d'énergie qui caractérise le trouble du pouvoir. En faisant des recherches, nous nous sommes rendus compte que toute déformation de la concentration d'énergie d'un signal donné, figue 3.6, construit le cœur de la déviation d'énergie. Nous comparons l'énergie du signal donné avec l'énergie du signal avec défaut, dont la formule ci-dessous :

$$DL(i)\% = \frac{NLPB(i) - NLSC(i)}{NLSC(8)} \times 100 \quad (3.34)$$

où :

$NLPB(i)$: La distribution d'énergie concentrée (avec défaut) sur chaque transformée en ondelette au niveau du signal étudié.

$NLSC(i)$: la distribution d'énergie dans chaque transformée en ondelette au niveau de la composante fondamentale correspondant au signal étudié.

$NLSC(8)$: la distribution d'énergie concentrée (avec défaut) sur les 8^{ième} (la plus haute énergie) de la composante fondamentale correspondant au signal étudié.

3.8.2 Réseaux Neuronaux Probabilistes (PNN)

Les réseaux neuronaux probabilistes peuvent être utilisés pour les problèmes de la classification. Le réseau peut être constitué de deux couches, la première couche des neurones de la fonction "radbas" pour calculer la distance entre le vecteur d'entrée et le vecteur d'apprentissage. La deuxième couche des neurones est la couche "compet" utilisée pour additionner les contributions pour chaque classe d'entrée afin de produire le vecteur de probabilité à la sortie du réseau (voir Figure 3.7) [68, 69, 70, 71, 72].

3.9 Analyse en Composantes Principales (ACP)

3.9.1 Introduction

L'analyse en composantes principales (ACP) a été introduite par Pearson et développée indépendamment par Hotelling. Bien que simple, elle est utilisée dans des domaines extrêmement divers (météorologie, économie, biologie, ..).

L'analyse en composantes principales (ACP) est une technique descriptive permettant d'étudier les relations qui existent entre les variables, sans tenir compte, a priori, d'une quelconque structure. Le but de l'ACP est d'identifier la structure de dépendance entre des observations multivariées afin d'obtenir une description ou une représentation compacte de ces dernières. Son utilisation a été restreinte à la projection des données sur les différents axes factoriels et au calcul de distances par rapport à ces axes comme outil de détection de valeurs aberrantes. L'utilisation de l'ACP de cette manière n'est pas très pratique, car un opérateur doit visualiser les projections pour prendre une décision quant à la présence de valeurs aberrantes. D'autres travaux ont été proposés d'utiliser l'analyse en composantes principales comme un outil de modélisation des processus à partir de laquelle un modèle peut être obtenu. Ainsi, cette alternative permet d'estimer les variables ou les paramètres du processus à surveiller.

Mathématiquement L'ACP vise à réduire le nombre de variables, c'est-à-dire la dimension du jeu de mesures de données, en exploitant la corrélation potentielle entre les variables initiales. Pour cela, elle propose de nouvelles variables décorrélatées et ordonnées de telle façon les premières retiennent le plus possible la variation présente dans les données initiales. Si les variables de départ sont très corrélées entre elles, l'information qu'elles donnent est très redondante et il suffira de considérer peu de nouvelles variables pour prendre en compte la plus grande partie de cette information.

L'estimation des paramètres du modèle ACP sera présentée dans ce chapitre par différents critères. Le critère considéré pour la détermination de la structure du modèle ACP est le critère de l'erreur de variance non reconstruite.

3.9.2 Principe de l'Analyse en Composantes Principales

La formulation d'un modèle de l'ACP est relativement simple. Considérons une matrice de données X avec n lignes et m colonnes, chaque variable est définie par une colonne et chaque observation par une ligne [19, 20, 21].

$$X = \begin{pmatrix} x_1(1) & x_2(1) & \dots & \dots & x_m(1) \\ x_1(2) & x_2(2) & \dots & \dots & x_m(2) \\ \cdot & \cdot & \dots & \dots & \cdot \\ \cdot & \cdot & \dots & \dots & \cdot \\ x_1(N) & x_2(N) & \dots & \dots & x_m(N) \end{pmatrix} \quad (3.35)$$

Afin de rendre le résultat indépendant des unités utilisées pour chaque variable, un prétraitement indispensable consiste à centrer et réduire les variables. Chaque colonne X_j de la nouvelle matrice centrée est donnée par :

$$X_j = \frac{X_j - M_j}{\dagger_j} \quad (3.36)$$

Ceci est fait pour éviter que certaines variables semblent dominantes dans l'analyse due seulement de leur amplitude par rapport aux autres variables. Une fois que les données ont été centrées, la matrice de corrélation de données, Σ , peut être calculée comme :

$$\Sigma = \frac{1}{N-1} X^T X \quad (3.37)$$

En analyse en composantes principales, un vecteur caractéristique $t \in \mathfrak{R}^\ell$ 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 maximisation de la variance de t . Les vecteurs t et X sont liés par une transformation linéaire $t = P^T X$, où la matrice de transformation $P \in \mathfrak{R}^{m \times \ell}$ vérifie la condition d'orthogonalité $P^T P = I$. Les colonnes de la matrice P forment les vecteurs de base orthonormés d'un sous-espace \mathfrak{R}^ℓ de représentation réduite des données. La transformation

linéaire s'apparente ainsi à une projection de l'espace des données de dimension m vers un sous-espace orthogonal de dimension n .

Les composantes t_j , avec $(j = 1, \dots, n)$, du vecteur caractéristique t représentent les composantes projetées du vecteur de données X dans ce sous-espace.

Le problème de l'ACP, considéré sous l'angle de la maximisation de la variance de projection des données, est celui de la détermination des vecteurs propres de la matrice de covariance Σ .

La variance de la projection, $\text{var}\{t\}$, s'identifie à sa valeur quadratique :

$$\begin{aligned} \text{var}\{t\} &= \text{var}\left\{\left(t - \{t\}\right)^2\right\} = \text{var}\{t^2\} \\ &= \text{var}\left\{\left(P^T X\right)\left(X^T P\right)\right\} \\ &= P^T \text{var}\{XX^T\}P = P^T \Sigma P \end{aligned} \quad (3.38)$$

La maximisation de la variance de la projection, sous condition de norme unité du vecteur p , est un problème d'optimisation sous contrainte égalité qui peut être résolu au moyen de la méthode des multiplicateurs de Lagrange. Sous cette dernière forme, le problème d'optimisation sous contrainte égalité maximisant la variance de la projection est formalisé par la fonction de Lagrange.

Notons par $\lambda_1, \lambda_2, \dots, \lambda_m$ les m valeurs propres de la matrice de covariance Σ et par $p_1, \dots, p_m \in \mathbb{R}^m$ les m vecteurs propres qui leur sont associés. Nous pouvons alors écrire :

$$\Sigma p_i = \lambda_i p_i \quad (3.39)$$

ou sous forme matricielle

$$\Sigma P = P \Lambda \quad (3.40)$$

avec $P = [p_1, p_2, \dots, p_m] \in \mathbb{R}^{m \times m}$ et $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_m) \in \mathbb{R}^{m \times m}$. En raison de la propriété de symétrie de la matrice de covariance Σ , les m valeurs propres λ_i sont réelles et les m vecteurs propres p_i sont distincts et orthogonaux. Si l'on ajoute à cette propriété la contrainte de norme unité, les vecteurs propres p_i ($i = 1, \dots, m$) forment une base orthonormée :

$$P^T P = P P^T = I_m \quad (3.41)$$

qui s'écrit sous forme développée :

$$p_i^T \Sigma p_j = \begin{cases} \lambda_i & \text{si } j = i \\ 0 & \text{si } j \neq i \end{cases} \quad (3.42)$$

De la comparaison des relations (3.38) et (3.42), il résulte :

$$\text{var} \{t\} = \text{V} \{t^2\} = p_i^T \Sigma p_i = \lambda_i, i=1, \dots, m \quad (3.43)$$

L'équation (3.43) révèle que les valeurs propres de la matrice de covariance représentent les variances des projections t_i des données sur les directions représentées par les vecteurs propres p_i ($i = 1, \dots, m$). En conclusion, la direction suivant laquelle la variance de la projection du vecteur de données X est maximale, est représentée par le vecteur propre p_i correspondant à la valeur propre maximale λ_i . Le second axe factoriel rend la variance maximale tout en étant orthogonal au premier. De façon plus générale, le sous-espace vectoriel de dimension k qui assure une dispersion maximale des observations est définie par une base orthonormée formée des k vecteurs propres correspondant aux k plus grandes valeurs propres de la matrice Σ . Une décomposition en valeurs propres de la matrice Σ , $\Sigma = P \Lambda P^T$ révèle la structure de la matrice de covariance.

La projection $t = P^T X$ d'un vecteur d'observation $X \in \mathcal{R}^m$ est le nouveau vecteur des variables transformées qui sont indépendantes et dont les variances sont les valeurs propres de la matrice Λ contenant les valeurs propres de Σ ordonnées dans l'ordre décroissant.

Les m vecteurs propres unitaires p_i de la matrice de covariance Σ représentent les m directions orthogonales de l'espace des données suivant lesquelles les variances des projections t_i des données sont maximales. Ces directions englobent donc l'ensemble de l'information véhiculée par les données. Aussi, l'espace engendré par les vecteurs propres constitue-t-il un espace de représentation optimale des données. Dans cet espace, les composantes principales t_i du vecteur de données X sont définies par :

$$t_i = p_i^T X = X^T p_i \quad i = 1, \dots, m \quad (3.44)$$

Celles-ci sont dénommées composantes principales et sont statistiquement non corrélées. En effet, en vertu des relations vectorielles

$$p_i^T \Sigma p_j = p_i^T v \left\{ XX^T \right\} p_j = v \left\{ p_i^T XX^T p_j \right\} = v \left\{ t_i t_j \right\} = 0 \quad i \neq j \quad (3.45)$$

La transposition matricielle des relations de projection de type (3.44) fournit l'expression analytique de l'analyse en composantes principales du vecteur de données X :

$$t = P^T X \quad (3.46)$$

où P^T représente la matrice de projection optimale des données au sens de l'analyse en composantes principales.

Rappelons que tout vecteur de données x peut être représenté par la combinaison linéaire des m vecteurs propres p_i ($i = 1, \dots, m$) de la matrice de covariance, pondérés par les composantes principales $t_i = p_i^T X$. L'estimation d'un vecteur de données x à partir de son vecteur de composantes principales associés t est triviale. Il suffit pour cela de multiplier à droite chacun des membres de l'équation (3.46) par P , il en découle :

$$X = P t = \sum_{i=1}^m t_i p_i \quad (3.47)$$

Il est donc possible de réduire la dimension de la représentation des données en ne retenant de l'expression (3.47) que les termes $t_j p_j$ ($j = 1 \dots \ell$) associés aux plus grandes valeurs propres λ_j . L'estimation \hat{X} d'un vecteur de données X est alors décrite par l'expression réduite :

$$\hat{X} = \sum_{i=1}^{\ell} t_i p_i = \sum (p_j^T X) p_j \quad (3.48)$$

Les données sont ainsi encodées par l'intermédiaire des ℓ composantes principales t_1, \dots, t_{ℓ} présentant les plus fortes variances, en comparaison des m valeurs descriptives x_1, \dots, x_m initialement requises.

La perte d'information induite par la réduction de dimension de représentation de chaque vecteur de données x est mesurée par la différence entre ses représentations exactes (3.47) et approchées (3.48) :

$$E = X - \hat{X} = \sum_{i=1}^m t_i p_i \quad (3.49)$$

Les $(m - \ell)$ composantes principales t_i ($i = \ell + 1, \dots, m$) à partir desquelles l'erreur d'estimation e est évaluée, sont associées aux plus faibles valeurs propres, $\lambda_{\ell+1}, \dots, \lambda_m$. Il est par conséquent bien évident que la compression de données préserve d'autant mieux l'information qu'elles véhiculent que ces valeurs propres sont de faibles valeurs. La somme des $m - \ell$ valeurs propres minimales quantifie par ailleurs la perte d'information :

$$v\{E^T E\} = \sum_{i=\ell+1}^m \lambda_i \quad (3.50)$$

Ainsi, le vecteur de données x peut être exprimé sous la forme :

$$X = \hat{X} + E \quad (3.51)$$

Dans la suite nous allons représenter la matrice des ℓ premiers vecteurs propres par \hat{P} , d'où :

$$\hat{t} = \hat{P}^T X \quad (3.52)$$

où \hat{t} est le vecteur des premières composantes principales et :

$$\hat{X} = \hat{C}X \quad \text{où} \quad \hat{C} = \hat{P}\hat{P}^T \quad (3.53)$$

Ainsi, l'erreur quadratique d'estimation est donnée par :

$$SPE = E^T E \quad (3.54)$$

Généralement, la procédure d'identification de modèles, consiste, après le choix d'une classe de modèle, à choisir une structure fixe puis à estimer les paramètres du modèle et enfin à valider ce modèle. Dans le cas de l'ACP, l'estimation des paramètres du modèle est très simple et revient en fait à un calcul de valeurs et vecteurs propres. Cependant le choix de la structure est plus délicat comme nous le verrons par la suite.

3.9.3 Détection des défauts

La génération de résidus a pour but de générer, à partir d'un modèle de bon fonctionnement du processus et des mesures observés, des signaux indicateurs de la présence de défauts. A partir de l'analyse de ces résidus, l'étape de prise de décision doit alors indiquer si un défaut est présent ou non. Il existe deux approches pour la génération des résidus : l'approche par estimation d'état et l'approche par estimation des paramètres.

3.9.3.1 Génération de résidus par estimation d'état

Dans le cas de l'analyse en composantes principales on retrouve le même principe. Concernant l'approche par estimation d'état, les résidus sont obtenus par un test de cohérence entre l'estimation et les mesures.

La présence d'un défaut affectant l'une des variables provoque un changement dans les corrélations entre les variables indiquant une situation inhabituelle car, les relations entre les variables ne sont plus vérifiées. Dans ce cas, la projection du vecteur de mesures dans le sous-espace des résidus va croître par rapport à sa valeur dans les conditions normales. Pour détecter un tel changement dans les corrélations entre les variables, l'ACPNL utilise généralement, la statistique SPE et la statistique SWE (Westerhuis). Cependant en pratique, la statistique SPE est généralement affectée par des erreurs de modélisation. Dans cette section, nous allons présenter les deux indices de détection utilisés avec l'ACPNL.

3.9.3.1.1 Statistique SPE

Une statistique typique pour détecter ces conditions anormales est la statistique SPE (Squared Prediction Error) l'erreur de prédiction quadratique, appelée aussi Q qui est donnée par l'équation :

$$SPE(k) = e(k)^T e(k) \quad (3.55)$$

Le processus est considéré en fonctionnement anormal (présence d'un défaut) à l'instant k si :

$$SPE(k) > u_r^2 \quad (3.56)$$

où δ_{α}^2 est le seuil de confiance du $SPE(k)$. soit $u_i = \sum_{j=\ell+1}^m \lambda_j^i$ pour $i= 1, 2, 3$ et λ_j est la $j^{ème}$ valeur propre de la matrice Σ .

Le seuil est approximé par:

$$u_r^2 = n_1 \left[\frac{c_r \sqrt{2 n_2 h_0^2}}{n_1} + 1 + \frac{n_2 h_0 (h_0 - 1)}{n_1} \right]^{\frac{1}{h_0}} \quad (3.57)$$

$$\text{où } h_0 = 1 - \frac{2n_1 n_3}{3n_2^2} \text{ et } c_r = \frac{n_1 \left[\left(\frac{\|e\|^2}{n_1} \right)^{h_0} - 1 - \frac{n_2 h_0 (h_0 - 1)}{2n_1} \right]}{\sqrt{2n_2 h_0^2}}$$

c_r est la limite au seuil de confiance $(1 - \alpha)$ dans le cas d'une distribution normale. Il faut noter que ce résultat est donné sous les conditions suivantes :

1. le vecteur des échantillons x suit une distribution normale multivariée,
2. une approximation est effectuée pour calculer le seuil u_r^2 du *SPE*.

Box a antérieurement montré que :

$$u_r^2 = g X_{h,r}^2 \quad (3.58)$$

où $g = n_2/n_1$ et $h = n_1^2/n_2$. Plus récemment, Nomikos et MacGregor ont démontré que les deux approximations données par les équations (3.57) et (3.58) sont équivalentes.

Pour le seuil de détection décrit précédemment est valable que pour un modèle ACP linéaire, mais pour un modèle ACPNL on fixe un seuil approprié.

3.9.3.1.2 Statistique SWE

Un autre indice de détection *SWE* (Squared Weighted Error) l'erreur quadratique pondérée, plus sensible au défaut, peut être défini comme le *SPE* pondéré par l'inverse de la variance des dernières composantes :

$$SWE(k) = x^T(k) \tilde{P} \Lambda_{(m-\ell)}^{-1} \tilde{P}^T x(k) \quad (3.59)$$

où $\Lambda_{(m-\ell)} = \text{diag}\{\lambda_{\ell+1}, \dots, \lambda_m\}$ est une matrice diagonale contenant les $(m - \ell)$ dernières valeurs propres de la matrice de corrélation Λ .

Cet indice suit une distribution du chi-2 avec $(m - \ell)$ degrés de liberté :

$$SWE(k) = \tilde{t}^T(k) \Lambda_{(m-\ell)}^{-1} \tilde{t}(k) \sim \chi_{(m-\ell), \gamma}^2 \quad (3.60)$$

Le processus est supposé en défaut si :

$$SWE(k) > \chi_{(m-\ell), \gamma}^2 \quad (3.61)$$

Il est important de noter que cet indice n'impose aucune supposition sur la distribution des variables du processus x , mais il suppose que les résidus $\tilde{t}(k) = \tilde{P}^T x(k)$ sont des bruits blancs gaussiens centrés.

Dans le cas d'un modèle non linéaire l'expression de SWE devient :

$$SWE = e^T(k)\Lambda^{-1}e(k) \tag{3.62}$$

où $\Lambda = \text{diag}\{\epsilon \text{ar}(e)\}$ est une matrice diagonale contenant les variances de l'erreur entre les mesures et les estimées.

3.9.4 Formulation MSPCA

La formulation de la méthode d'analyse en composante principale multi-échelle consiste à considérer la matrice $X_{n,m}$ avec n échantillons et m variables. Chaque m colonnes de la matrice $X_{n,m}$ sont décomposées individuellement en appliquant la DWT. L'approximation de l'ondelette A_L de chaque des m décompositions sont collectées dans une matrice de dimension $m \times n/2^L$ (figure 3.7). De la même façon, les coefficients de détails de l'ondelette (D_1 à D_L), pour chaque niveau, sont regroupés dans leur matrice correspondante de dimension $m \times n/2^i$ avec $i = 1, 2, \dots, L$. Le nombre de matrices ainsi construit est $L+1$ matrices, où sur laquelle nous allons appliquer l'ACP. Notre objectif est d'extraire la corrélation entre les différents capteurs, en se basant sur l'indice de performance SPE [22, 23, 24].

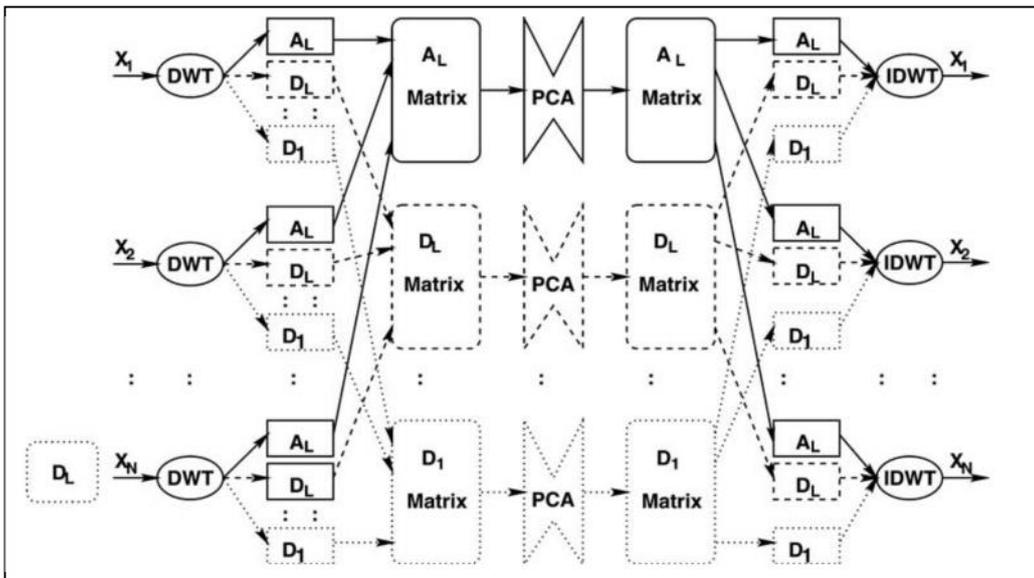


Figure 3.7 ACP Multi-échelle :

Lignes continues : modèle des approximations de l'ondelette
 Lignes pointillées : l'ondelette détaillée des modèles.

3.10 Conclusion

Dans ce chapitre, plusieurs méthodes de transformées en ondelettes ont été présentées. Ce sont les méthodes les plus couramment utilisées dans le domaine de traitement de signal. Nous avons, également, présenté une méthode couramment utilisée pour la transformée en ondelette, cette méthode est l'analyse multirésolution qui est basée sur l'espace d'approximation et l'espace de détail qui utilise la DWT (transformée en ondelette discrète) pour l'analyse temps échelle des signaux en particulier les signaux non stationnaires.

Cette technique de décomposition sera utilisée sur les signaux, à différents niveaux de décomposition, Nous avons utilisé cette technique pour associer l'ACP et la DWT.

3.11 Références bibliographiques

- [1] KEVIN BNGLECHART, PHILIP PARKER, BENARD HUDGINS, *Wavelet method in biomedical, Signal processing*, CRC PRESS LLC, 2003.
- [2] O. CASTRO, C. SISAMON, J. OARCIA PARADA, *Bearing fault diagnosis based on neural network classification and wavelet transform*, Proceedings of 6th wseas international, 2006.
- [3] S. STOER, M. S. TAQQU, CH. PARK, *On the wavelet spectrum diagnostic for hart parameter estimation in the analysis of internet traffic*, University of North Carolina at chapel Aill, 2004.
- [4] B. SWARUP, R. KAUSHIK, S. JAUNE, *A Novel wavelet transform based transient current analysis for fault detection and localization*, IBF Computer society, 2002.
- [5] JOE AIR JIANG, *A fault detection and faulted phase selection Approach for transmission lines with Harr wavelet transform*, IEEE, 2003.
- [6] B. AYLANT, MO. YUEN. CHOW, M. HYUN SONG, *Multiple signatures processing based fault detection schems for broken rotor bar in induction motors*, IEEE Transaction on energy conversion vol. 20, (2005).
- [7] H. DOUGLAS, P. PILLAY, T.H.ORTMEGER, *The application of wavelets to ship board power systems protection*, IEEE, Electric ship technologic symposium, 2005.
- [8] R.PHILIPPE, *Cours d'ondelettes*, ESPEO– Université d'Orléans, 2001-2002.
- [9] J. LIN, M. O. ZOU, *Gear box fault diagnosis using adaptive wavelet filter*, Mechanical systems and signal processing 17(6), 1259, 1269, 2003.
- [10] HAI QUI, JAY LOE, JING LIN, GANG YU, *Wavelet filter based weak signature detection method and its application on rolling element bearing prognostics*, Journal of sound and vibration 289-1066-1090, (2006).
- [11] ZWE-LEE GAING, *Wavelet-based neural network for power disturbance recognition and classification*, IEEE, Trans. Power Delivery, vol. 19, 2004).
- [12] V. DIMIMH MIH NHAT, Suny young lee, *Two dimensional, weighted PCA algorithm for face recognition*, Proceedings, 2005, IEEE, International symposium on computational intelligence in robotics and automation.
- [13] O. CASTRO, C. SISAMON, J. OARCIA PARADA, *Bearing fault diagnosis based on neural network classification and wavelet transform*, Proceedings of 6th wseas international, 2006.
- [14] OIAN JIN GUO, HARIBIN YU, AIDONG XU, *Modified morlet wavelet neural networks for fault detection*, IEEE, 2005.

- [15] Sorsa T., Koivo H. N. et Koivisto H., *Neural Networks in Process Fault Diagnosis*, IEEE trans. System Man & Cybernetics, Vol.21 N°4, P.815-825, July/Aug. 1991.
- [16] Chow M. Y., *The Advantages of Machine Fault Detection Using Artificial Neural Network and Fuzzy Logic technologies*, Proceedings of IEEE Intern. Conference on Industrial Technology, 5-9/12/1994.
- [17] Boek M. J., *Experiments in the Application of Neural Networks to Rotating Machine Fault Diagnosis*, IEEE Intern. Joint Conf. on Neural Network, Vol.1, pp.769-774, 1991.
- [18] Keyvan S., Durg A. et Rabelo C., *Evaluation of the Performance of Various Artificial Neural Networks to the Signal Fault Diagnosis in Nuclear Reactor Systems*, IEEE, P.1719-1723, 1994.
- [19] M.F. HARKAT, *Détection et localisation de défauts par analyse en composantes principales*, Thèse de doctorat de l'institut National Polytechnique de Lorraine, 30 juin 2003.
- [20] H. HENRY YUE, M.TOMOYASU, *Weighted principal component analysis and its applications to improve FDC performance*, IEEE, 2004.
- [21] R. SHAO, F. JIA, E. B. MARTIN, A .J. MORRIS, *Wavelet and nonlinear principal components analysis for processes monitoring*, Control engineering practice 7-865-879, 1999.
- [22] M. MISRA, H.HENRY YUE, S.JOE QIN, CHENY LING, *Multivariate process monitoring and fault diagnosis by multi-scale PCA*, Computers and chemical engineering 26- 1281-1293, 2002.
- [23] R. BHAVIK, BAKSHI, *Making the most of process information via multiscale and Bayesian methods*, Ohio state university, 2002.
- [24] H. BARADHYE, R.BHAVIK, R.BAKSHI, A. ROMON, STRANSS JAMES, F. DAVIS, *Multiscale SPG using Wavelets, theoretical analysis and properties*, 2002.
- [25] D. PICARD, *Analyse en composantes indépendantes par ondelettes*, Thèse de doctorat de l'université Paris 7 Denis Diderot UFR de Mathématiques, 5 décembre 2006.
- [26] V. Venkata, Subramanian, R. RENGASWAMG, K. YIN, *A review of process fault detection and diagnosis Part I: Quantitative model-based methods*, Computers and chemical Engineering 26.1281-1293, (2002).
- [27] M. ELTABACH, A. CHARARA, I. ZEIN, *A comparison of external and internal methods of signal spectral analysis for broken rotor bars detection in Induction Motors*, IEEE, Transaction, on Industrial electronic, vol. 51, 2004.
- [28] M. AIELLO, A. CATALIOTTI, S. NUCCIO, *A Comparison of spectrum estimation techniques for non-stationary signals in Induction motor drive measurements*, IEEE, Transactions, on instrumentation and measurement, vol. 54, 2005.
- [29] R.PHILIPPE, *Cours d'ondelettes*, ESPEO– Université d'Orléans, 2002-2001.
- [30] MAO. YE. YUE WU and ZHANG YI, *Global convergence analysis of a PCA learning algorithm*, IEEE, Trans. power electronics. 2002.
- [31] HAIQING. WANG, LIPING. ZHONGXUE YUAN, *Understanding PCA fault detection results by using expectation analysis method*, Proceeding of the 41st, IEEE, 2002.
- [32] K. HOTTA, VIEW, *Invariant face detection method based on local PCA cells*, IEEE, 2003.
- [33] KEVIN BNGLECHART, PHILIP PARKER, BENARD HUDGINS, *Wavelet method in biomedical, Signal processing*, CRC PRESS LLC, 2003.
- [34] S. STOER, M. S. TAQQU, CH. PARK, *On the wavelet spectrum diagnostic for hart parameter estimation in the analysis of internet traffic*, University of North Carolina at chapel Aill, 2004.
- [35] Y. OUSSAR, G. DREYFUS, *Initialization by selection for wavelet network training*, Published in Neuro computing vol. 34, pp 131-143, 2000.

- [36] B. SWARUP, R. KAUSHIK, S. JAUNE, *A Novel wavelet transform based transient current analysis for fault detection and localization*, IBF Computer society, 2002.
- [37] JOE AIR JIANG, *A fault detection and faulted phase selection Approach for transmission lines with Harr wavelet transform*, IEEE, 2003.
- [38] B. AYLANT, MO. YUEN. CHOW, M. HYUN SONG, *Multiple signatures processing based fault detection schems for broken rotor bar in induction motors*, IEEE Transaction on energy conversion vol. 20, (2005).
- [39] H. DOUGLAS, P. PILLAY, T.H.ORTMEGER, *The application of wavelets to ship board power systems protection*, IEEE, Electric ship technologic symposium, 2005.
- [40] C. COMBASTEL, S.LESECQ, S.PETROPOL, S.GENTIL, *Model based and wavelet approaches to induction motor on line fault detection*, Control engineering practice, 2002.
- [41] P. ABRY, V. PIPIRAS, *Wavelet based synthesis of the Rosenblatt process*, Signal processing, 2005.
- [42] P. ZHANG, S. X. DING, G. Z. WARG, D.H. ZHOU, *An FDI approach for sampled data systems*, Proceedings of the American control conference, 2001.
- [43] R. SONG, N. SEPEHR, *Fault detection and isolation in fluid power system using a parametric estimation method*, IEEE, 2002.
- [44] S. GENTIL, J. MONTMAIN, CH. COMBASTEL, *Combining FDI and AI approaches with in causal model based diagnosis*, IEEE, Transaction on systems, vol. 34, 2004.
- [45] I. SZASZI, B. KULESAR, G. J. BALAS, J. BOKOR, *Design of FDI filter form an aircraft control system*, IEEE, 2002.
- [46] G. WESLEY, E. ZANARDELLI, G. ELIAS STRANGAS, HASSANK K. KHALIL, JOHN M. MILLER, *Wavelet based methods for the prognosis of mechanical and electrical failures in electric motors*, Mechanical systems and signal processing 19-411-426, (2005).
- [47] X. LI, SH. DONG, Z. YUAN, *Discret wavelet transform for tool breakage monitoring*, *International journal of machine tools manufacture*, 99-1955-1944, 1999.
- [48] N. BACHSCHMID, P. PENNACCHI, *Identification of multiple faults in rotor systems*, *Journal of sound and vibration* 254(2)-327-366, 2002.
- [49] Procaccia H., Piepszownik, *Fiabilité des Equipements et Théorie de la Décision Statistique Fréquentielle et Bayésienne*, Edition EYROLLES, 1992, N°81.
- [50] Nandi A. K., Dickie J. A. et Smith J. A., *Classification of Conditions of Rotating Machines Using Higher Order Statistics*, IEE Colloquium 'Higher Order Statistics in Signal Processing: Are They of any Use?' Digest N° 1995/111.
- [51] Nico Roos, *Efficient Model-Based Diagnosis*, Intelligent Systems Engineering, summer 1993.

4. Chapitre 4 : L'Analyse en composante indépendante (séparation aveugle des sources)

4.1 Introduction

Dans le milieu industriel, cas des machines tournantes, les vibrations sont causées par plusieurs organes de la machines (arbre, engrenage, roulement, ...), et il est très difficile de savoir la source de la vibration. Le premier pas pour répondre à ce problème, consiste à bien choisir l'emplacement des capteurs. Le deuxième est d'identifier les signaux d'entrés à base des signaux captés, d'où l'utilisation de la séparation aveugle de sources (BSS).

L'idée fondamentale de la séparation aveugle de sources (BSS) est d'identifier les signaux de la source d'entrée du système de leur mélange observé sur les capteurs. L'identification des sources de bruit a toujours été une préoccupation constante et la connaissance des sources de bruit dominantes à l'égard de leurs contributions à des niveaux de bruit globaux fournit des informations précieuses pour les applications de contrôle du bruit. Les procédés classiques d'identification de bruit peuvent être divisés en plusieurs catégories : l'évaluation subjective, l'analyse du trajet de transmission, l'analyse de temps et de la fréquence d'analyse. La sélection de l'une ou l'ensemble des méthodes ci-dessus dépend des objectifs et des ressources disponibles dans la pratique.

L'évaluation subjective repose sur la capacité de détection exceptionnelle de l'oreille humaine et le cerveau. Il a été démontré que l'oreille humaine et le cerveau combinés ensemble ont la capacité de reconnaître les différents motifs de bruit. Cela a été confirmé par de nombreux exemples où des techniciens industriels expérimentés ont effectué des tâches cruciales d'évaluation du bruit avec plus de succès que d'instruments sophistiqués. Bien que ce procédé donne souvent des descriptions qualitatives des caractéristiques de la source de bruit, son effet est limité lorsqu'un nouveau système compliqué est l'objet. En outre, l'environnement de travail est strictement limité par la loi afin de prévenir la perte d'audition et des lésions cérébrales.

L'analyse du chemin de transmission est très utile dans la recherche de sources de bruit du système. En étudiant les principes physiques du processus, les sources de certains signaux dominants ont été identifiés et tel que discuté dans [1, 2]. Le bruit transmis rayonne ainsi à partir des surfaces de la structure du processus jusqu'à ce qu'il atteigne le récepteur. Un grand

nombre de formules quantitatives ont été proposés pour décrire la relation entre les niveaux de bruit du système et les dimensions géométriques du processus.

L'analyse des données observées peut être réalisée soit dans le domaine temporel ou dans le domaine fréquentiel. L'analyse de fréquence est utilisée pour déterminer les composantes de fréquence des signaux de bruit mesurés et dans la plupart des cas, une transformation de Fourier est suffisante pour décomposer les composants. Une autre application de l'analyse de fréquence est d'utiliser la méthode de la cohérence pour déterminer la relation entre les entrées et sorties [3].

Comparativement, l'analyse de l'isolation proposée fournit des résultats estimés plus précis et plus fiables. L'analyse d'isolation basée sur les BSSFs est une méthode efficace pour déterminer la contribution d'une source particulière. Une des stratégies les plus simples est d'éteindre une seule partie du processus et de comparer les changements des niveaux de bruit. Le changement de niveaux est détecté par une analyse statistique appropriée. La nécessité d'adopter une analyse statistique est basée sur la mesure de la variabilité de la dissymétrie afin d'obtenir une compréhension claire du comportement du processus, la détection de l'occurrence d'événements spéciaux ou assignables et l'identification rapide des causes les plus probables. L'approche d'analyse en composantes indépendantes (ICA) apporte des algorithmes fondamentalement différents dans la façon de traiter le problème de la séparation de source. Il suppose que les données de mesure sont déterminées par les sources latentes non observées. L'objectif de l'ACI est de séparer, à partir des seules données observées, les sources latentes, cela est devenu la réalisation la plus attractive de la séparation aveugle de sources (BSS). L'ACI a été rapporté d'avoir séparé avec succès les données de l'électroencéphalogramme du cerveau (EEG), des signaux de parole, traitement de réseau d'antenne, traitement d'image, extraction de caractéristiques, les applications de télécommunication et de financière [2, 3, 4, 5, 6, 7].

4.2 Séparation aveugle de sources (Blind source separation BSS)

La nécessité d'une séparation de signal peut être illustrée dans un scénario appelé "cocktail-party problem" [8, 9]. Le scénario suppose qu'il y a deux personnes dans une chambre, parlent en même temps, tandis que deux microphones sont placés dans deux emplacements différents dans la même chambre. Les deux signaux de parole produits par les deux haut-parleurs sont dénotés par $s_1(t)$ et $s_2(t)$ respectivement. Les deux enregistrements

des deux microphones $x_1(t)$ et $x_2(t)$ sont une combinaison linéaire des signaux de parole, comme suit:

$$\begin{cases} x_1(t) = a_{11}s_1(t) + a_{12}s_2(t) \\ x_2(t) = a_{21}s_1(t) + a_{22}s_2(t) \end{cases} \quad (4.1)$$

où les paramètres sur la droite dépendent des distances de microphone et l'acoustique. Dans la pratique, il est difficile de déterminer leurs valeurs et dans ce cas ils sont censés être inconnus. Il est également supposé que les signaux de source de la parole ne sont pas observés, sauf qu'ils sont statistiquement indépendants. Par conséquent, seuls les enregistrements des microphones sont disponibles. Le problème cocktail-party ci-dessus se préoccupe par la séparation des signaux de parole latente non observés et des enregistrements. Une fois qu'ils ont été séparés l'étude des signaux de parole peut être étudiée plus facilement.

Une idée naturelle pour séparer les signaux de parole est de résoudre l'équation linéaire ci-dessus par des méthodes algébriques. Malheureusement, à la fois les paramètres de mélange et les signaux de parole d'origine ne sont pas connus, il est donc impossible de résoudre l'équation en utilisant les méthodes algébriques classiques. Ce problème cocktail-party classique implique l'idée de la séparation aveugle de sources (BSS) : récupérer les signaux de source latente d'origine des mélanges mesurés [4]. La seule connaissance a priori est l'hypothèse que les sources sont statistiquement indépendantes.

L'idée de la séparation aveugle de sources (ou signal) a été proposée par Héroult et al. en 1985 [12]. L'ACI (Analyse en composante indépendante), considérée comme une extension de l'analyse en composantes principales (ACP) et sous-jacente au principe de la BSS, a également été abordée par les mêmes auteurs dans les années 1980 [8]. Common était le premier auteur à définir les fondements mathématiques de l'ACI, qui a été développée avec succès, devenant une référence dans la BSS et que les termes de l'ACI et la BSS sont souvent utilisés indifféremment [4, 5]. Cela signifie qu'elles se réfèrent à la même définition, le modèle et les algorithmes de mise en œuvre. Dans les sections suivantes, l'ACI sera utilisé à la place de la BSS.

4.3 Analyse en composantes indépendantes (ACI)

Le modèle ACI peut être généralisé à partir du "*cocktail-party problem*" précédant en décrivant le problème sous une forme plus abstraite. La réécriture de l'équation (4.1) au format matricielle donne :

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (4.2)$$

où le vecteur de la source $\mathbf{s} = [s_1, s_2, \dots, s_n]^T$ est composé de n éléments sources statistiquement indépendantes. \mathbf{A} est la matrice $n \times m$, également connu comme la matrice de mélange. Dans la pratique, à la fois le vecteur de sources latentes et la matrice de mélange ne sont pas observables. Le vecteur de sortie est la seule observation disponible par m capteurs. Maintenant, le but de l'Accord est de trouver une séparation ou matrice de séparation $\mathbf{W}_{n \times m}$ de sorte que les sources latentes peuvent être récupérées comme suit:

$$\mathbf{y} = \mathbf{W}\mathbf{x} = \mathbf{W}\mathbf{A}\mathbf{s} \quad (4.3)$$

où $\mathbf{y} = [y_1, y_2, \dots, y_n]^T$ est le vecteur des sources séparées.

Le cœur du problème de la BSS et l'ACI peut être déclaré comme suit: étant donné m réalisations indépendantes du vecteur d'observation \mathbf{x} , trouver une estimation de l'inverse de la matrice de mélange [9]. Le problème de base, dans ce cas, est que la matrice de mélange est totalement inconnue ou non-existante, qui explique donc pourquoi les méthodes algébriques classiques sont exclues. Il convient également de noter que le vecteur estimé \mathbf{y} est appelé une copie du vecteur des sources \mathbf{s} [4]. La copie implique que les deux vecteurs ne sont pas exactement les mêmes et ces différences seront abordées dans la section suivante.

L'ensemble du processus de l'ACI peut être illustré dans le schéma bloc de la figure 4.1. L'ACI impose des hypothèses et des restrictions sur les observations, les sources et la matrice de mélange.

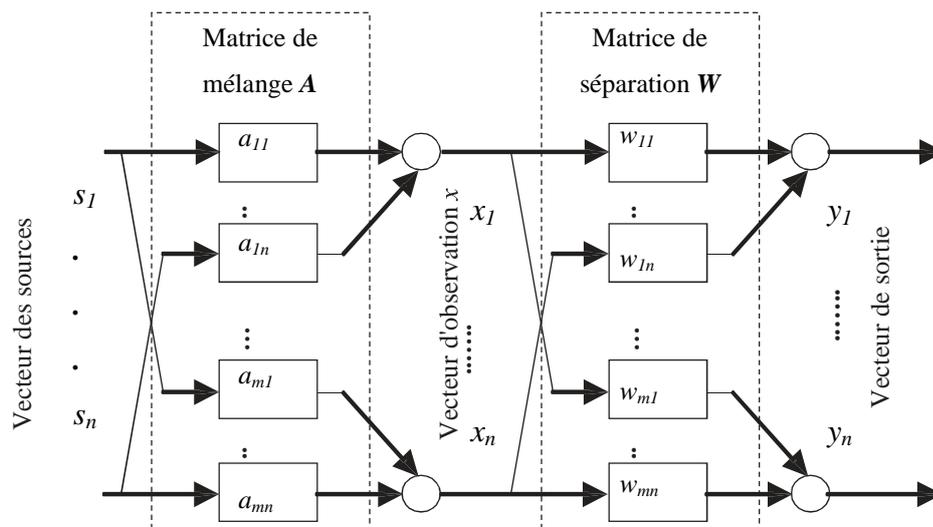


Figure 4.1 Principes du modèle ACI

Avant de procéder à l'ACI, les données observées doivent être prétraitées. La première étape de l'ACI est le blanchiment, ce qui élimine toute corrélation entre les variables aléatoires. Cela signifie de faire le vecteur des entrées observées n'ont corrélé entre elles et qui ont la variance unité, mais elles ne sont pas indépendantes. Le Blanchiment est habituellement effectué en utilisant la théorie de la décomposition en valeurs propres qui factorise la matrice de covariance observée sous la forme suivante [4] :

$$\text{Cov}(\mathbf{x}, \mathbf{x}) = E(\mathbf{x}\mathbf{x}^T) = \mathbf{Q} \mathbf{Q}^T \quad (4.4)$$

où \mathbf{Q} est la matrice orthonormée contenant les vecteurs propres spécifiés par $\mathbf{Q}^T \mathbf{Q} = \mathbf{I}$.

est la matrice diagonale contenant les valeurs propres dans un ordre décroissant, c'est-à-dire, $\mathbf{\Lambda} = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_m\}$ avec $\lambda_1 > \lambda_2 > \dots > \lambda_m$. Après cette décomposition, un nouveau vecteur peut être construit comme suit :

$$\tilde{\mathbf{x}} = \mathbf{\Lambda}^{-\frac{1}{2}} \mathbf{Q}^T \mathbf{x} \quad (4.5)$$

Il peut être prouvé que le nouveau vecteur a une matrice de covariance unité, c'est-à-dire

$$\text{Cov}(\tilde{\mathbf{x}}, \tilde{\mathbf{x}}) = E(\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T) = \mathbf{I} \quad (4.6)$$

Le blanchiment est donc accompli et apporte une nouvelle matrice de mélange

$$\tilde{\mathbf{A}} = \mathbf{\Lambda}^{-\frac{1}{2}} \mathbf{Q}^T \mathbf{A} \quad (4.7)$$

Comme il est souvent supposé que le vecteur de source a une matrice de covariance unité, par exemple $E(\mathbf{s}\mathbf{s}^T) = \mathbf{I}$, la nouvelle matrice de mélange est également orthonormée.

Ceci réduit de manière significative la dimension de la matrice. Par exemple, une matrice carrée ordinaire a m^2 degrés de liberté. Une matrice orthonormée a seulement $m(m-1)/2$ degrés de liberté. Si m est assez grand, alors le nombre de degrés est réduit à près de la moitié de la taille originale. Cela implique que, après le blanchiment, l'ACI a besoin d'estimer moins d'éléments de la matrice et donc son calcul peut être accéléré de manière significative [22].

4.4 L'algorithme de maximisation de l'information

L'ACI peut être mise en œuvre par plusieurs façons qui forment les différents algorithmes d'ACI tels que la neg-entropie [8, 15], l'algorithme du point fixe [16, 18], l'estimation du maximum de vraisemblance [3, 17], la divergence de Kullback-Leibler [5, 11], des moments d'ordre supérieur et cumulant [8], l'algorithme modifié de Héroult-Jutten [7]

et la maximisation de l'information [2, 23]. La plus grande différence entre les algorithmes ci-dessus repose sur la conception de fonctions d'optimisation. Bien qu'il y ait beaucoup d'algorithmes différents, ils ont un objectif commun : la récupération de l'indépendance statistique des entrées du vecteur de sorties, soit en maximisant ou minimisant les fonctions de contraste. Le choix des fonctions de contraste optimisées forme ainsi les algorithmes ci-dessus et il a été montré que la plupart des algorithmes ACI ont beaucoup d'équivalence entre elles [3, 19]. D'autres différences sont liées aux caractéristiques de stabilité et de convergence de l'algorithme. Dans cette section, l'algorithme de maximisation d'informations sera utilisé en raison de sa stratégie d'apprentissage efficace.

L'algorithme de maximisation de l'information a été développé par Bell et Sejnowski [2] et Roth et Baram [27] indépendamment. La fonction de contraste établie pour cet algorithme maximise l'entropie des entrées du vecteur de sorties. Dans l'ACI, l'indépendance entre deux variables peut être justifiée par leur information mutuelle, comme suit:

$$I(y_1, y_2) = \iint p_{y_1, y_2}(y_1, y_2) \log \left(\frac{p_{y_1, y_2}(y_1, y_2)}{p_{y_1}(y_1)p_{y_2}(y_2)} \right) dy_1 dy_2 \quad (4.8)$$

où $p_{y_1, y_2}(y_1, y_2)$ est la fonction de densité de probabilité commune, $p_{y_1}(y_1)$ et $p_{y_2}(y_2)$ sont les fonctions de densité de probabilité marginales.

D'après la définition, on peut voir que l'information mutuelle est à la fois symétrique et non négatif, c'est-à-dire, $I(y_1, y_2) = I(y_2, y_1)$ et $I(y_1, y_2) \geq 0$. Les zéros sont atteints si et seulement si les deux variables sont statistiquement indépendantes et accidentellement, cela apporte l'algorithme de minimisation de l'information mutuelle. L'information mutuelle est sélectionnée par la minimisation de la fonction de contraste.

La relation entre l'information mutuelle et l'entropie est définie par Bell and T.J.[2] et Haykin et Chen [11] :

$$I(y, x) = H(y) - H(y|x) \quad (4.9)$$

où $H(y)$ est l'entropie conjointe du vecteur de sortie et $H(y|x)$ est l'entropie conditionnelle. L'entropie est une mesure de la quantité d'information incertaine contenue dans le vecteur ou variable. Il est défini comme :

$$H(x) = - \int p_x(x) \log p_x(x) dx = -E \log p_x(x) \quad (4.10)$$

Dans le cas de l'entropie variable, c'est $H(x) = 0$, cela implique que la survenance de l'événement est clair et entièrement prévisible.

D'autre part, l'entropie maximale correspond à l'incertitude maximale et il peut être montré qu'une variable gaussienne a l'entropie maximale parmi toutes les distributions. Cela implique que les variables gaussiennes ne peuvent pas être séparées en utilisant l'ACI [7]. L'entropie conditionnelle $H(y|x)$ contient du bruit de réseau qui n'a pas de rapport avec le vecteur d'entrée au cours de l'optimisation [26]. La fonction de contraste pour l'algorithme de maximisation d'informations maximise l'information mutuelle entre l'entrée et les vecteurs de sortie tels que décrits dans l'équation (4.9). C'est parce que l'entropie conditionnelle sur le côté droit n'est pas lié à l'optimisation, maximisant ainsi l'information mutuelle, est le même que l'optimisation de l'entropie conjointe de sortie. Il est à noter que l'information mutuelle maximale dans l'équation (4.9) est défini entre le vecteur d'entrée x et le vecteur de sortie y . Par conséquent, le but de l'optimisation est d'extraire autant d'informations que possible à partir du vecteur d'entrée. Sinon, le vecteur de sortie n'a pas de sens s'il contient peu d'informations d'entrée.

4.4 Méthodologie proposée

Le volume et la nature des données, qu'elles sont des mesures bruitées, observations manquantes, variables non indépendantes et rapport signal/bruit petit nécessitent l'adoption de techniques de projection statistiques multivariées pour obtenir une meilleure compréhension du comportement des processus, la détection de l'apparition des événements spéciaux ou assignables et l'identification rapide des causes les plus probables. L'approche de l'analyse en composantes indépendantes (ACI) a démontré des résultats positifs dans le domaine de la surveillance de processus [9, 22, 29]. Leur principe est basé sur la vérification en continue des informations essentielles contenues dans la mesure en définissant de nouvelles variables, de composantes indépendantes, qui expliquent la variabilité des sources dans les données du processus. Les nouvelles variables sont une combinaison linéaire des variables initiales qui sont limités pour être indépendantes.

Dans une situation aléatoire, l'approche de détection et d'isolation des défauts (FDI) est basée sur deux principes : d'une part, la collecte d'un ensemble de données en mode sain (acquisition) avec une construction de différents filtres de séparation aveugle de sources (BSSF) et l'analyse statistique de leurs signaux, d'autre part, de tester les composants du BSSF en fonction des caractéristiques statistiques dans le mode défaillant.

4.4.1 Les filtres de séparation aveugle de source

(Blind Source Separation filters BSSF)

Nous allons étudier les applications des BSSF dans l'identification des défauts dans un processus. Chaque BSSF est composé de manière à trouver la relation entre les données mesurées et les signaux de source dans laquelle l'ACI est utilisée comme un outil pour définir une série de nouvelles variables. Ces variables sont linéairement indépendantes et mélangées de la manière suivante :

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \quad (4.11)$$

où le vecteur $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T$ représente les signaux observés principalement en rapport avec les mesures $\mathbf{s}(t)$ des variables des entrées et de sorties et l'occurrence des défauts sur les capteurs qui sont corrompus par le bruit $\mathbf{n}(t)$. Comme mentionné précédemment, l'objectif de la BSS est d'identifier les sources et la matrice de mélange $A_{n \times m}$. Ces caractéristiques font de l'approche aveugle très polyvalente car elle ne repose pas sur la modélisation des phénomènes physiques.

Pour surmonter les effets du bruit des systèmes qui se superposent sur le signal de mesure réel, la BSS est considérée comme une technique qui élimine le bruit à partir des données acquises. Basée sur le rapport signal sur bruit (SNR) et le critère de l'erreur quadratique moyenne (Mean Square Error, MSE) qui sont respectivement donnés par [25] :

$$SNR_j = 10 \log_{10} \left(\frac{\sum_i (x_{ji}^{us})^2}{\sum_i (x_{ji} - x_{ji}^{us})^2} \right) \quad (4.12)$$

et

$$MSE_j = \frac{1}{N} \sum_i (x_{ji} - x_{ji}^{us})^2 \quad (4.13)$$

où x_{ji}^{us} et x_{ji} représentent les signaux non corrompus et corrompus respectivement du canal j ($j = 1, 2, \dots, n$) à l'instant d'échantillonnage i ($i = 1, 2, \dots, l$). l est le nombre maximal d'échantillons. Nous définissons un modèle BSS qui dépend du bon choix de l'ordre et de la dimension des composantes indépendantes. Il n'y a pas de critère standard pour le choix de l'ordre des composantes indépendantes, ce qui complique la procédure du choix de l'ordre. Un certain nombre de méthodes ont été proposées pour le choix de l'ordre des composantes indépendantes [1, 16, 20]. Dans ce travail, nous avons utilisé une norme euclidienne pour

trier les lignes de la matrice de séparation W , en raison de sa simplicité. Par conséquent, l'ordre des composantes indépendantes est fixé sur la norme L_2 de chaque ligne w_i de W :

$$\arg(\max_i \|w_i\|_2) \quad (4.14)$$

Une fois l'ordre des composantes indépendantes est fixé, il est nécessaire de déterminer leur nombre optimal à être sélectionné pour la procédure de débruitage. Cette étape est cruciale car la sélection de trop de composantes indépendantes augmentera le bruit tandis qu'un petit nombre ne sera pas suffisant pour saisir les caractéristiques dominantes du processus. Nous utilisons une technique graphique pour représenter le niveau normal des lignes de la matrice de séparation et l'évaluation du SNR et la MSE pour chaque modèle de BSS choisi. Ainsi, la dimension d'un modèle BSS est réduite en sélectionnant quelques rangés de W qui possèdent le plus grand effet sur la variation estimée de sources séparées y . Les lignes de W sont séparées en une partie dominante W_d et une partie non dominante W_r . Les matrices obtenues présentent les formes suivantes:

$$y(t) = \begin{bmatrix} y_d(t) \\ y_r(t) \end{bmatrix} = \begin{bmatrix} W_d \\ W_r \end{bmatrix} x(t) \quad (4.15)$$

La source dominante y_d estimée est utilisée dans la construction des signaux filtrés

$$x_f(t) = (W_d^T W_d)^{-1} W_d^T y_d(t) \quad (4.16)$$

La détection et l'isolation des défauts agissant sur les dispositifs de mesure d'un processus donné sont généralement réalisées en utilisant les données disponibles dans le mode sain et défectueux. Les BSSFs sont obtenus par une technique d'ACI dans laquelle chacun d'entre eux utilise une partie seulement des signaux filtrés disponibles. Pour chaque schéma de BSSF, nous éliminons un signal à partir des variables d'entrée et de sortie mesurées. Le principe de diagnostic de défauts par un banc de BSSF est représenté sur la figure 4.2. D'un point de vue pratique, le problème de diagnostic de défauts est généralement réalisé par une analyse statistique qui teste avec précision les changements brusques dans la situation saine du processus. L'analyse statistique est appliquée à tous les éléments indépendants du banc de BSSF. Le défaut est détecté si les caractéristiques statistiques de chaque composant de BSSF ne changent pas en mouvement à partir d'une expérience à l'autre. Les sources de chaque BSSF, qui ne sont pas corrompues par des défauts, localisent avec précision le signal qui est le sujet de l'apparition du défaut.

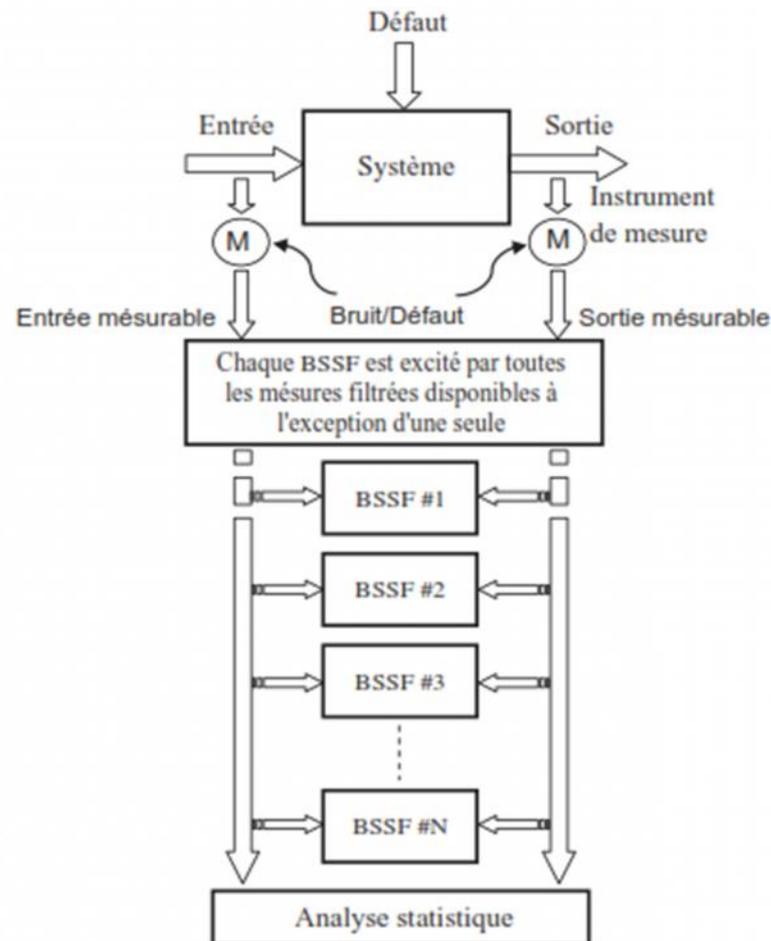


Figure 4.2 Diagramme de diagnostic et isolation de défauts utilisant les BSSFs et l'analyse statistique

4.4.2 L'analyse statistique

Dans la pratique, la variabilité de signal peut résulter seulement des erreurs de mesure aléatoires. Cependant, les dynamiques sont souvent négligées en tant que source d'erreurs importantes causant des variations paramétriques dans le processus global. Les constantes thermodynamiques et les paramètres géométriques sont généralement incertains et peuvent changer au cours du processus d'exploitation. Pour ces raisons, il est avantageux d'utiliser une technique spécifique basée sur la dissymétrie (skewness) pour une meilleure détection des défauts des systèmes stochastiques.

La dissymétrie est une mesure de l'asymétrie de données autour de la moyenne de l'échantillon. Si la dissymétrie est négative, les données sont réparties plus à gauche de la moyenne que vers la droite. Si la dissymétrie est positive, les données sont réparties plus à droite. La dissymétrie d'une distribution est définie comme :

$$S = \frac{E(X - \mu)^3}{\sigma^3} \quad (4.17)$$

où μ et σ représentent la moyenne et l'écart-type de X , respectivement, et $E(t)$ est la valeur attendue de la quantité t . La dissymétrie est calculée pour tous les composants du BSSF et utilisée comme un index pour la détection de défaut.

4.5 Domaines d'application de l'ACI

L'utilisation de l'ACI a connu beaucoup de succès dans plusieurs domaines. Pour cela, beaucoup de chercheurs ont appliqué leur algorithme à des cas plus ou moins concrets. Dans ce paragraphe nous allons citer quelques cas mais à titre indicatif sans limitation.

4.5.1 Séparation de signaux de parole

Une première application est la séparation de signaux de parole, telle que présentée dans le problème "cocktail-party problem" [30].

4.5.2 Imagerie médicale

Une classe importante de problème résolu par le modèle instantané linéaire d'ACI concerne les applications en imagerie médicale, en particulier la détermination de l'activité cérébrale [30]. Celle-ci est étudiée à l'aide de deux types d'images: les images encéphalographiques d'une part et les images obtenues par résonance magnétique d'une autre part.

L'activité électrique du cerveau peut être détectée à l'aide d'enregistrement électro-encéphalographiques (EEG) ou magnéto-encéphalographiques (MEG) puisque toute activité électrique induit aussi bien un champ électrique que magnétique. Les ERPs (*Event-Related Potentials*) sont des enregistrements sur des patients qui réagissent plusieurs fois à un même stimulus et qui ont été moyennées en vue d'augmenter leur rapport signal sur bruit. La boîte crânienne agit comme un filtre passe-bas sur les signaux provenant du cerveau mais l'hypothèse de superposition linéaire de signaux reste néanmoins valide. Si on suppose d'autre part que les activations cervicales sont temporellement indépendantes, il n'en n'est pas de même spatialement puisque plusieurs lieux peuvent être actifs simultanément. Cette technique ne permet pas donc d'effectuer la localisation spatiale des sources mais plutôt une localisation temporelle d'un ensemble d'activités. Notons néanmoins que puisque la somme d'activités indépendantes tend vers une distribution gaussienne, l'ACI peut théoriquement avoir quelques

difficultés pour faire la séparation. En pratique, l'utilisation de l'algorithme de Bell & Sejnoski permet de détecter des variations faibles par rapport à la distribution normale. Vigário et ses collègues ont quant à eux appliqué l'algorithme "FastICA" à des données EEG et MEG.

4.5.3 Données financières

Une première application de l'ACI à des données financières a utilisé comme données d'entrées le cours des actions des 28 plus grosses entreprises cotées à la bourse de Tokyo entre 1986 et 1989 [30]. Afin d'avoir des signaux stationnaires, ils s'intéressent en fait au "retour d'action" qui est la différence entre deux valeurs successives du cours. En appliquant l'algorithme JADE sur de telles données, ils espèrent trouver des facteurs indépendants dont l'interprétation expliquerait les structures sous-jacentes des marchés d'actions. Ils montrent en particulier que l'ACI permet une mise en évidence de phénomènes plus intéressants que l'ACP. De plus l'utilisation des quatre composantes indépendantes les plus dominantes (définie à partir de l'amplitude maximale) permet retrouver l'essentiel de la variation du cours de la principale banque japonaise.

4.5.4 Classification et reconnaissance d'image

Appliquée à des images naturelles, l'ACI permet de faire émerger les structures fondamentales de celle-ci (les "bords"). Cette capacité d'adaptation aux données a naturellement été utilisée pour des applications de reconnaissance et discrimination d'image. Dans le domaine de la fusion audio-visuelle en particulier, la cohérence entre le mouvement des lèvres d'un locuteur et les caractéristiques spectrales de son [30].

4.5.4 Diagnostique et isolation de défauts

L'application de l'ACI dans le domaine du diagnostic et la surveillance des défauts est très prometteuse. Qiang et al. [31] ont appliqué l'ACI pour la caractérisation des défauts de roulement. Les auteurs ont appliqué leur technique sur des signaux vibratoires prélevés d'un banc d'essai. Les signaux concernent un roulement dans l'état normal, d'un roulement avec un défaut sur la bague interne (inner race fault) et un troisième avec un défaut sur la bague externe (outer race fault). La technique consiste à appliquer la décomposition en mode empirique (Empirical Mode Decomposition EMD) et après les composantes indépendantes sont extraites qui incluent les signatures des défauts en mode spectral figure 4.3.

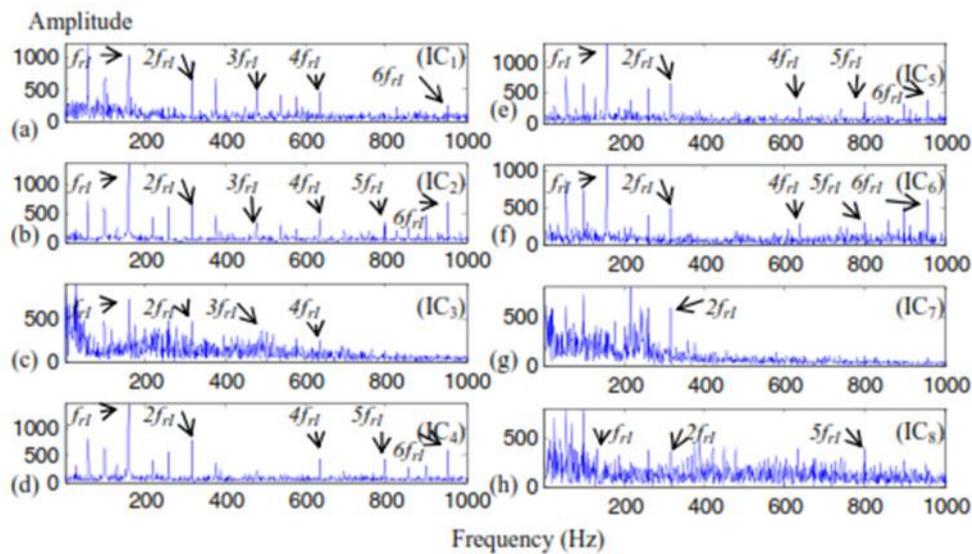


Figure 4.3 Spectre des composantes indépendantes du défaut sur la cage interne du roulement après application de la EMD

4.6 Conclusion

L'analyse en composantes indépendantes (ACI) est une méthode statistique d'analyse de données récemment développée pour traiter des observations vectorielles (multivariées) afin d'en extraire des composantes linéaires aussi indépendantes que possible. Cette technique émergente peut être effectuée tant par une approche algébrique que neuronale.

Le volume et la nature des données, qu'elles sont des mesures bruitées, observations manquantes, variables non indépendantes et rapport signal/bruit petit nécessitent l'adoption de techniques de projection statistiques multivariées pour obtenir une meilleure compréhension du comportement des processus, la détection de l'apparition des événements spéciaux ou assignables et l'identification rapide des causes les plus probables. L'approche de l'analyse en composantes indépendantes (ACI) a démontré des résultats positifs dans le domaine de la surveillance de processus. Leur principe est basé sur la vérification en continue des informations essentielles contenues dans la mesure en définissant de nouvelles variables, de composantes indépendantes, qui expliquent la variabilité des sources dans les données du processus. Les nouvelles variables sont une combinaison linéaire des variables initiales qui sont limitées pour être indépendantes.

Dans une situation aléatoire, l'approche de détection et d'isolation des défauts est basée sur deux principes : d'une part, la collecte d'un ensemble de données en mode sain (acquisition) avec une construction de différents filtres de séparation aveugle de sources

(BSSF) et l'analyse statistique de leurs signaux, d'autre part, de tester les composants du BSSF en fonction des caractéristiques statistiques dans le mode défaillant.

4.7 Références bibliographiques

- [1] A.D. Back and A.S. Weigned, *A first application of independent component analysis to extracting structure from stock returns*, Int. J. Neural Syst. 8(4) (1997), pp. 473–484.
- [2] A.J. Bell and T.J. Sejnowski, *An information maximisation approach to blind separation and blind deconvolution*. Neural Comput. 7(6) (1995), pp. 1129–1159.
- [3] J-F. Cardoso, *Infomax and maximum likelihood for source separation*, IEEE Lett. Signal Process. 4(4) (1997), pp. 112–114.
- [4] J-F. Cardoso, *Blind signal separation: Statistical principles*. Proc. IEEE 90(8) (1998), pp. 2009–2026.
- [5] J-F. Cardoso and D.L. Donoho, *Some experiments on independent component analysis of non-Gaussian processes*, Proc. IEEE SP Int. Workshop on High Order Stat. (1999), pp. 74–77.
- [6] J-R. Cardoso and A. Souloumia, *Blind beam forming for non-Gaussian signals*, IEEE Proc. Part F 140 (1993), pp. 362–370.
- [7] A. Cichocki, R. Unbehauen, L. Moszczynski, and E. Rummert, *A new on-line adaptive algorithm for blind separation of source signals*, Proc. Int. Symp. Artif. Neural Netw. (1994), pp. 406–411.
- [8] P. Comon, *Independent component analysis, a new concept*. Signal Process. 36 (1994), pp. 287–314.
- [9] Z. Ge and Z. Song, *Process monitoring based on independent component analysis-principal component analysis (ICA-PCA) and similarity factors*, Ind. Eng. Chem. Res. 46 (2007), pp. 2054–2063.
- [10] F. George and B.M. Golam Kibria, *Confidence intervals for estimating the population signal to noise ratio: A simulation study*, J. Appl. Stat. 39 (2012), pp. 1225–1240.
- [11] S. Haykin and Z. Chen, *The cocktail party problem*. Neural Comput. 17(9) (2005), pp. 1875–1902.
- [12] J. Herault, C. Jutten and B. Ans, *Détection de grandeurs primitives dans un message composite par une architecture de calcul neuromimétique en apprentissage non supervisé*, Colloque du GRETSI 1 (1985), pp.1017–1022.
- [13] S-W. Hwang, Jeong W-B., Yoo W-S. and K-H. Kim, *Transmission path analysis of noise and vibration in a rotary compressor by statistical energy analysis*, J. Mech. Sci. Technol. 18(9) (2004), pp. 1909–1915.
- [14] M.H. Hyun and S.S. Kim, *A study on the transmission path of shipboard structure-borne noise using SEA*, J. Korean Soc. Noise Vib Eng. 6(5) (1996), pp. 575–585.
- [15] A. Hyvärinen, *Fast and robust fixed-point algorithms for independent component analysis*, IEEE Trans. Neural Netw. 10 (1999), pp. 626–634.
- [16] A. Hyvärinen, *Survey on independent component analysis*, Neural Comput. Surv. 2 (1999), pp. 94–128.
- [17] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, Wiley, New York, 2001.
- [18] A. Hyvärinen and E. Oja, *A fast fixed-point algorithm for independent component analysis*, Neural Comput. 9 (1997), p. 1483.

- [19] A. Hyvärinen and E. Oja, *Independent component analysis: Algorithms and applications*, Neural Netw. 13(4/5) (2000), pp. 411–430.
- [20] M. Kano, S. Tanaka, S. Hasebe, and I. Hashimoto, *Monitoring independent components for fault detection*. AIChE J. 49(4) (2003), pp. 969–976.
- [21] M. Lal Mehta, *Random Matrices*, Elsevier, The Netherlands, 2004.
- [22] J-M. Lee, C. Yoo, and I-B. Lee, *Statistical process monitoring with independent component analysis*, J. Process Control 14 (2004), pp. 467–485.
- [23] [24] T. Lee, *Independent Component Analysis: Theory and Applications*, Kluwer Academic Publishers, Boston, MA, 1998.
- [24] S. Makeig, A. Delorme, M. Westerfield, T-P. Jung, J. Townsend, E. Courchesne and T.J. Sejnowski, *Electroencephalographic brain dynamics following visual targets requiring manual responses, EEG dynamics following visual targets*, Public Library of Science Biology (2004). Available at <http://sccn.ucsd.edu/~scott/pdf/PLOS04.pdf>
- [25] Z. Nenadic and J.W. Burdick, *Spike detection using the continuous wavelet transform*, IEEE Trans. Biomed. Eng. 52(1) (2005), pp. 74–87.
- [26] N. Parga and J-P. Nadal, *Blind source separation with time dependent mixtures*, Signal Process. 80(10) (2000), pp. 2187–2194.
- [27] Z. Roth and Y. Baram, *Multidimensional density shaping by sigmoids*. IEEE Trans. Neural Netw. 7(5) (1996), pp. 1291–1298.
- [28] J. Wu, X. Liu, and J. Feng, *Detecting causality between different frequencies*, J. Neurosci. Methods 167 (2008), pp. 367–375.
- [29] C.K. Yoo, J-M. Lee, P.A. Vanrolleghem, and I-B. Lee, *On-line monitoring of batch process using multiway independent component analysis*, Chemometr. Intell. Lab. Syst. 71 (2004), pp. 151–163.
- [30] H. Le Borgne, *Analyse de Scènes Naturelles par Composantes Indépendantes*, Thèse de Doctorat, 30/01/2004, Institut National Polytechnique de Grenoble. http://www.eeng.dcu.ie/~th_le_borgne.pdf
- [31] Q. Miao, D. Wang, M. Pecht, *Rolling Element Bearing Fault Feature Extraction Using EMD-Based Independent Component Analysis*, 978-1-4244-9826-0/11/\$26.00 ©2011 IEEE

5. Chapitre 5 : Applications aux systèmes physiques

5.1 Application 1 : Diagnostic de l'endommagement de roulement de machine tournante

5.1.1 Introduction

Cette partie est consacrée à l'étude en simulation de la détection de défauts basée sur l'utilisation des deux méthodes, l'ondelette et l'ACP, principalement. Les résultats numériques que nous allons exposer sont obtenus à partir des algorithmes que nous avons développé sous *MATLAB* et appliqué pour la détection des défauts de roulement sur un banc d'essai.

Dans les machines tournantes, les roulements et les pignons (engrenages) sont généralement les premiers et principales sources d'incidents. Dans les roulements la détérioration des billes ou des couronnes (bagues), se traduit par une augmentation du niveau de vibration et de bruit.

5.1.2 Description du roulement à billes

On appelle roulement, un ensemble de pièces insérées entre deux organes mobiles l'un par rapport à l'autre et destinées à remplacer un glissement (Figure 5.1).

Un roulement est composé de quatre éléments principaux (Figure 5.2) :

- Bague extérieure (outer race)
- Bague intérieure (inner race)
- Cage
- Des billes

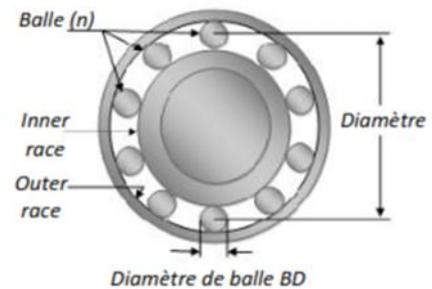
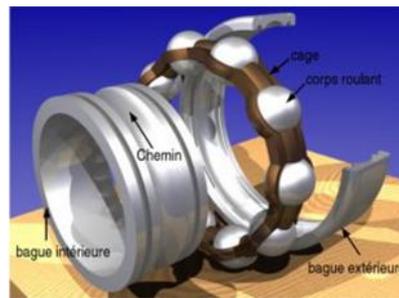
La figure 5.2 (b) donne la géométrie du roulement à bille et les principaux paramètres de celui-ci, à savoir : le nombre de billes ' n ', le diamètre de la bille ' BD ' et en fin le diamètre de pitch ' PD '. Les fréquences vibratoires caractéristiques dues aux défauts de roulement, peuvent être calculées à partir de la fréquence de rotation de l'arbre f_{rm} et la géométrie du roulement (Fig.5.2 (b)):

$$f_{OD} = \frac{n}{2} f_{rm} \left(1 - \frac{BD}{PD} \cos \{ \right) \quad (5.1)$$

$$f_{ID} = \frac{n}{2} f_{rm} \left(1 + \frac{BD}{PD} \cos \{ \right) \quad (5.2)$$

$$f_{BD} = \frac{PD}{2BD} f_m \left(1 - \left(\frac{BD}{PD} \right)^2 \cos^2 \xi \right) \quad (5.3)$$

Où f_{OD} est la fréquence vibratoire caractéristique du défaut de la bague extérieure (Outer race), f_{ID} est la fréquence vibratoire caractéristique du défaut de la bague intérieure (Inner race) et f_{BD} est la fréquence vibratoire caractéristique du défaut de la balle (Ball).



(a)

(b)

Figure 5.1 Roulement à billes

Figure 5.2 Composants (a) et géométrie (b) d'un roulement

5.1.3 Présentation du banc d'essai

La figure 5.3, montre le banc d'essai sur lequel, il y'a eu les prélèvements vibratoires. Il est composé d'un moteur électrique (à gauche), un couple transducteur/encodeur (au centre), un dynamomètre (à droite) et bien évident un équipement de contrôle électronique (ni pas sur la photo) [1].

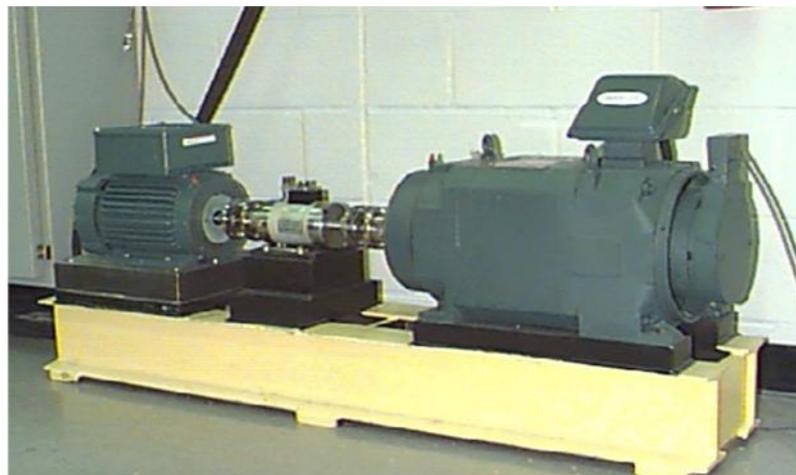


Figure 5.3 Banc d'essai de machine tournante

Les roulements en test soutiennent l'arbre moteur. Un seul point de défauts est introduit au roulement en test en utilisant une machine à décharge électrique. Les roulements utilisés dans l'expérience, sont de marque SKF. Les défauts, respectivement, sont:

- une rayure de diamètre 7 mils (1 mil=0,001 inches = 0,0254 mm) sur la bague interne (inner race)
- une rayure sur la balle
- une rayure de diamètre 7 mils (1 mil=0,001 inches = 0,0254 mm) sur la bague externe (outer race).

Les tableaux 5.1 et 5.2 donnent les spécifications géométriques et les fréquences de défauts respectivement.

diamètre interne	diamètre externe	épaisseur	diamètre de balle	diamètre du pitch
25	52	15	7,94	39,04

Table 5.1 Géométrie du roulement (en mm)

bague interne	bague externe	cage	élément en rotation
5.4152	3.5848	0.39828	4.7135

Table 5.2 Les fréquences de défaut (multiple de la vitesse de rotation en Hz)

Les données vibratoires ont été collectées en utilisant des accéléromètres, qui étaient attachés au foyer vibratoire avec des bases magnétiques. Les accéléromètres étaient placés dans la position 12o'clock. Dans certaines expériences un accéléromètre est bien fixé à la base supportant le moteur.

Les signaux vibratoires ont été acquis via un enregistreur DAT à 16 canaux et ont subi un prétraitement sous Matlab. Les données ont été acquises à 12 000 échantillons par seconde. Les données de vitesse et de puissance ont été prises sur le couple transducteur/encodeur. Les défauts de rayures sur la bague externe sont stationnaires ; cependant, l'emplacement des défauts par rapport à la zone de charge du roulement a un impact direct sur la réponse vibratoire du système. Pour quantifier cet effet, les expériences ont été menées avec un défaut de rayures sur la bague extérieure localisé à 3o'clock (directement dans la zone de charge), à

6o'clock (perpendiculaire à la zone de charge) et à 12o'clock. La vitesse de rotation (fréquence) de l'arbre est de 1750 rpm (29.2Hz), approximativement.

5.1.4 Résultats et discussion

Les signaux de mesure utilisés pour tester les algorithmes développés sont des signatures pour un roulement sain et un roulement défectueux avec différents niveaux, à savoir le défaut inner rice (bague interne), le défaut outer rice (bague externe) et le défaut de Ball. La mise en œuvre de cette expérimentation et selon la démarche suivante :

- ✓ Placer quatre (04) capteurs dans différentes positions pour acquérir des signatures reflétant le comportement réel de la machine tournante.
- ✓ Acquérir pour chaque cas (roulement sain, roulement défectueux avec un défaut inner rice, un défaut outer rice et un défaut de Balle) quatre (04) acquisitions en utilisant quatre (04) capteurs.
- ✓ Décomposer les signatures de vibration en utilisant la DWT jusqu'au cinquième niveau.
- ✓ Construire des matrices par les coefficients d'approximation et les coefficients de détails des différents cas de défauts ($A_L, D_L, D_{L-1}, \dots, D_1$).
- ✓ Appliquer les matrices ($A_L, D_L, D_{L-1}, \dots, D_1$) aux entrées de la structure MSPCA.
- ✓ Tester la corrélation entre les différents Coefficients.
- ✓ Calculer la SPE et la comparer avec un seuil de 95% de l'amplitude maximale pour un roulement sain.
- ✓ Si la SPE viole l'amplitude maximale du coefficient de détail, le roulement présente un défaut, si non le roulement est considéré sain.

Pour mieux illustrer cette démarche, nous avons tracé les courbes temporelles (Figure 5.4 à Figure 5.7) ci-dessous. La figure (Figure 5.4) présente les acquisitions des quatre capteurs pour un roulement sain. Les défauts Inner rice, Outer Rice et le défaut de balle sont représentés par les figures (Figure 5.5 à Figure 5.7). Une première appréciation sur le comportement temporel des différentes signatures réside au niveau de leurs amplitudes reflétant la gravité de l'endommagement du roulement. Ce pendant l'examen visuel ne suffit pas pour décider la défaillance d'un système.

A cette effet, il est nécessaire voir obligatoire d'utiliser une entité sous forme d'un critère quadratique, entre autre la SPE.

Si la SPE dépasse un seuil de 95% prédéfini par rapport à l'amplitude maximale d'un roulement neuf, nous pouvons annoncer la présence d'un défaut. Généralement ces défauts

sont de nature hautes fréquences, c'est la raison pour laquelle nous avons utilisé les coefficients de détails de la DWT d'un signal de vibration.

Les figures 5.8 à 5.23, représentent les coefficients de détails des différentes signatures avec les différents défauts. Encore avec un examen visuel, nous pouvons remarquer la différence entre les coefficients de détails d'un signal de vibration d'un roulement sain et ceux affectés avec les défauts Inner rice, Outer Rice et défaut de balle. Le test de corrélation entre les différentes signatures est illustré par le calcul des valeurs propres (Figure 5.25, 5.27, 5.29, 5.31, 5.33, 5.35, 5.37, 5.39, 5.41 et 5.43). Le nombre des composantes retenues est validé par l'ordre des valeurs propres. Si l'ordre de la valeur propre est très faible, nous pouvons l'éliminer. L'erreur commise par cette approximation constitue la SPE. La détection d'un défaut est justifiée par le test de la SPE par rapport au seuil (Figure 5.24, 5.26, 5.28, 5.30, 5.32, 5.34, 5.36, 5.40 et 5.42).

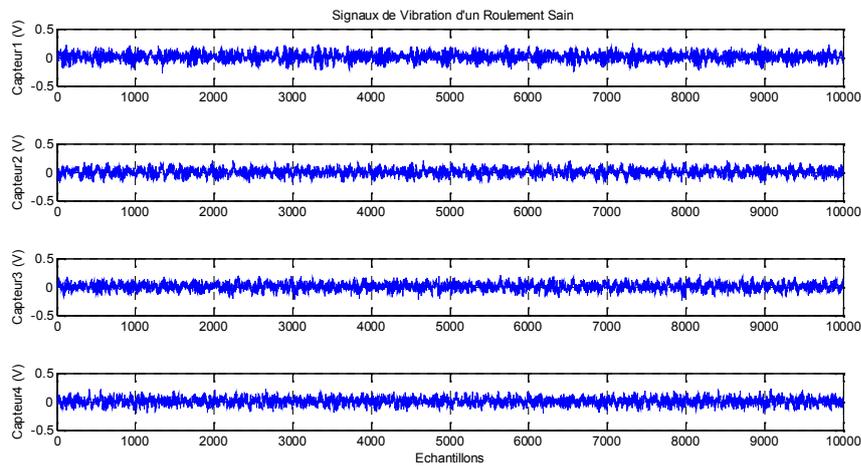


Figure 5.4 Signaux de vibration d'un roulement neuf

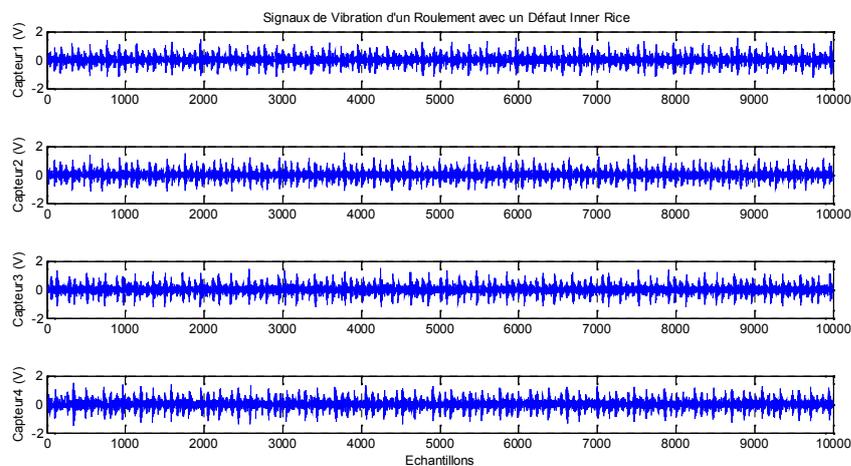


Figure 5.5 Signaux de vibration d'un roulement avec un défaut inner rice

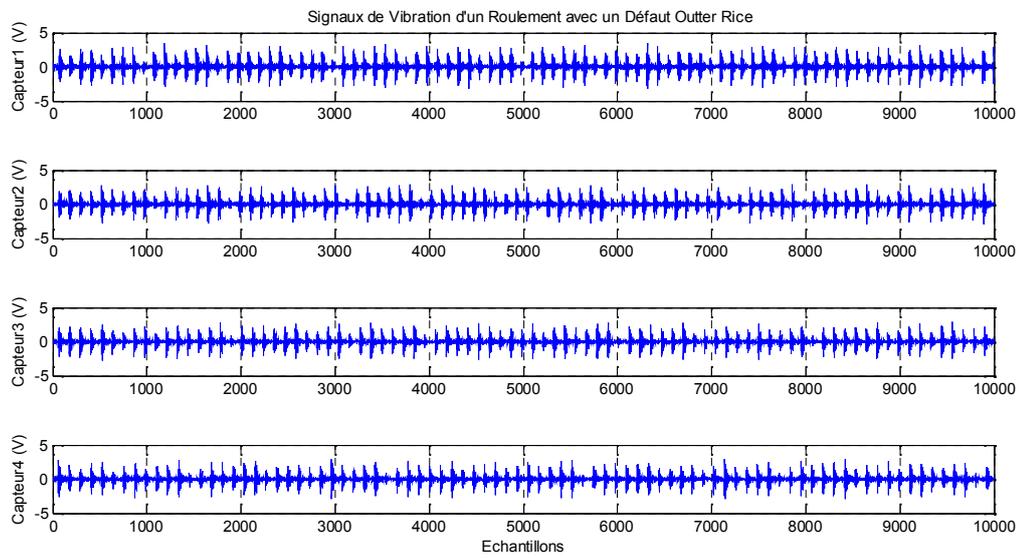


Figure 5.6 Signaux de vibration d'un roulement avec un défaut outer rice

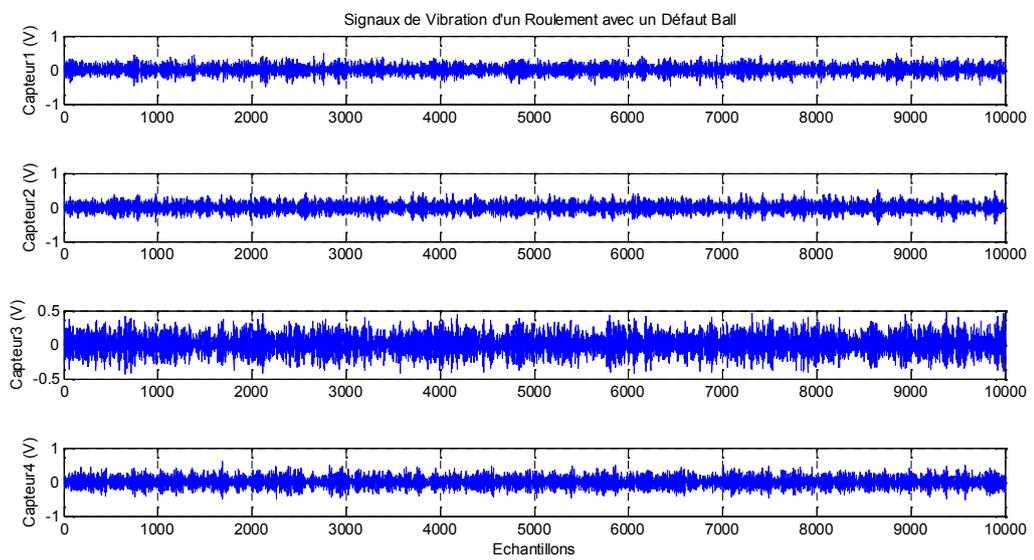


Figure 5.7 Signaux de vibration d'un roulement avec un défaut de balle

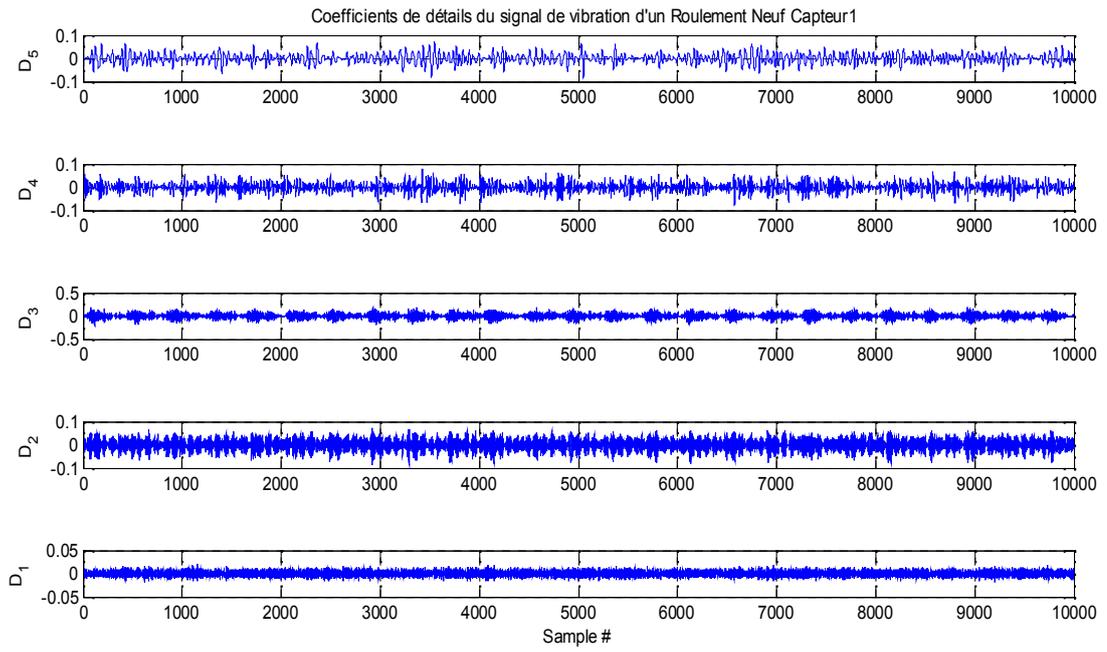


Figure 5.8 Coefficients de détail (niveau 5) d'un roulement neuf du capteur #01

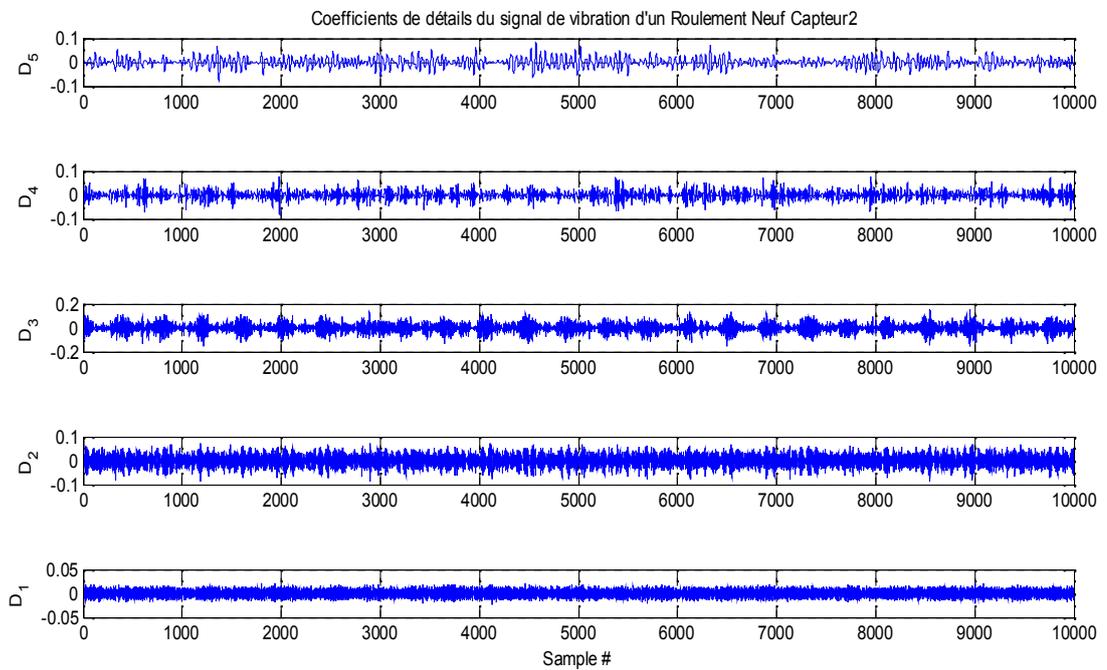


Figure 5.9 Coefficients de détail (niveau 5) d'un roulement neuf du capteur #02

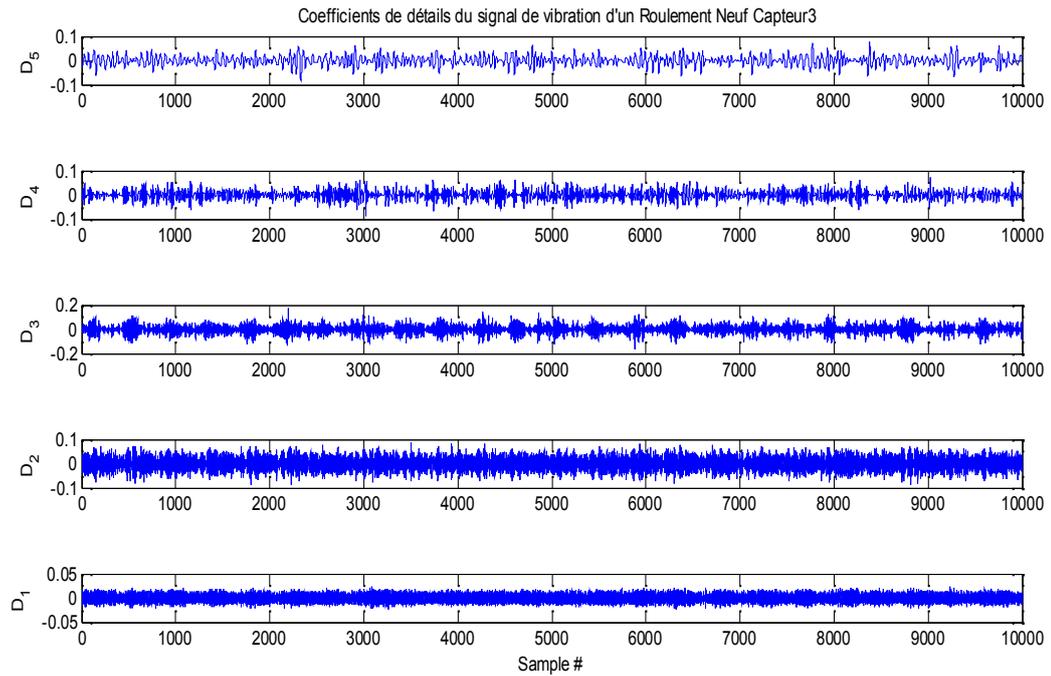


Figure 5.10 Coefficients de détail (niveau 5) d'un roulement neuf du capteur #03

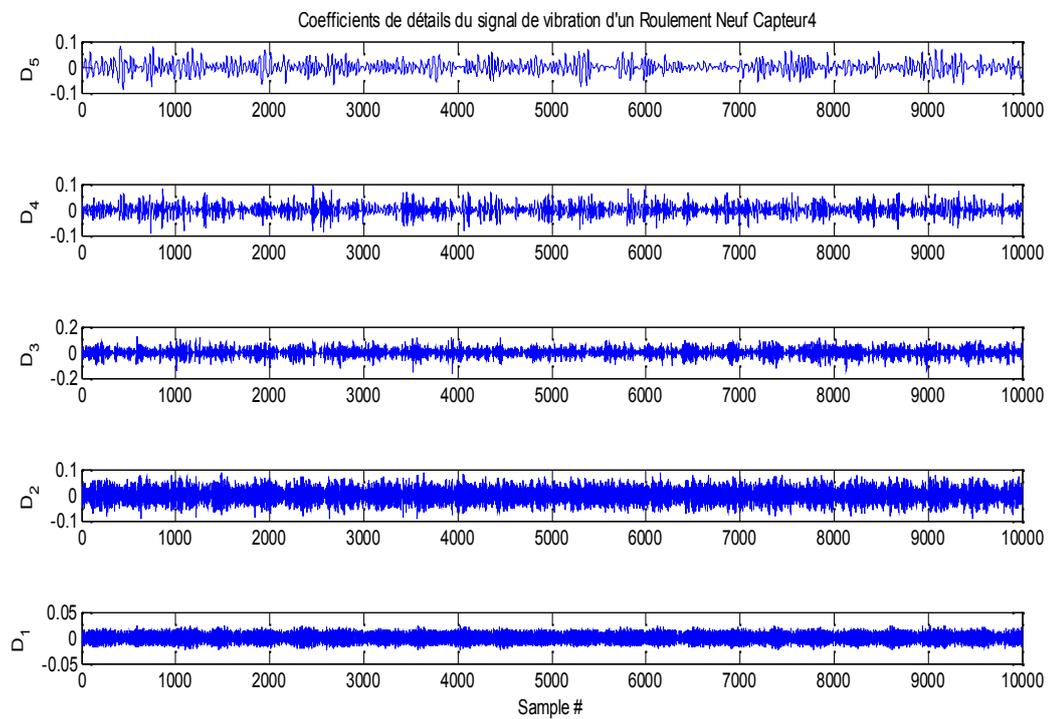


Figure 5.11 Coefficients de détail (niveau 5) d'un roulement neuf du capteur #04

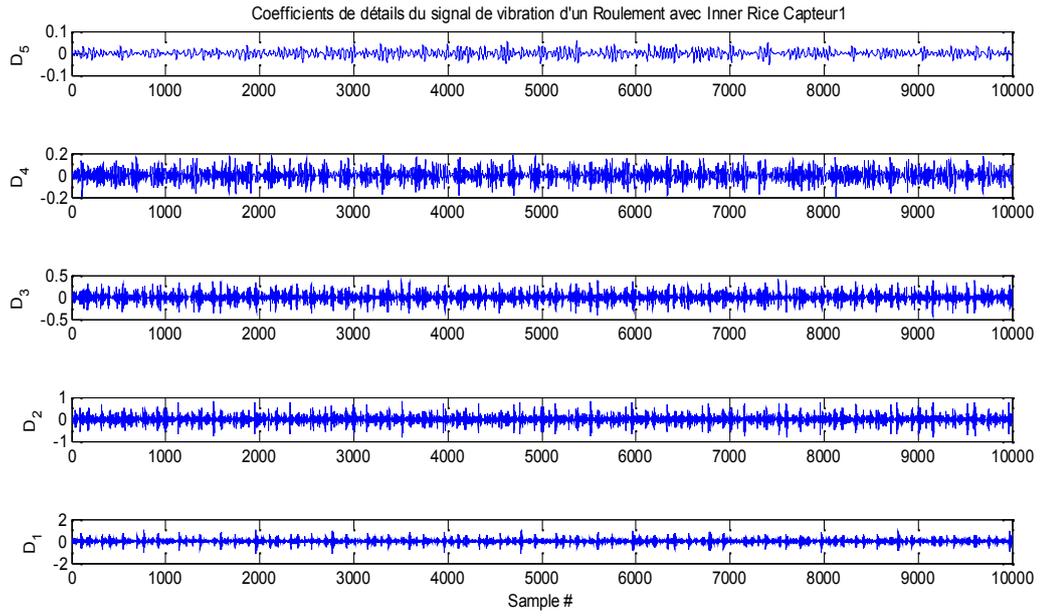


Figure 5.12 Coefficients de détail (niveau 5) avec un défaut inner rice du capteur #01

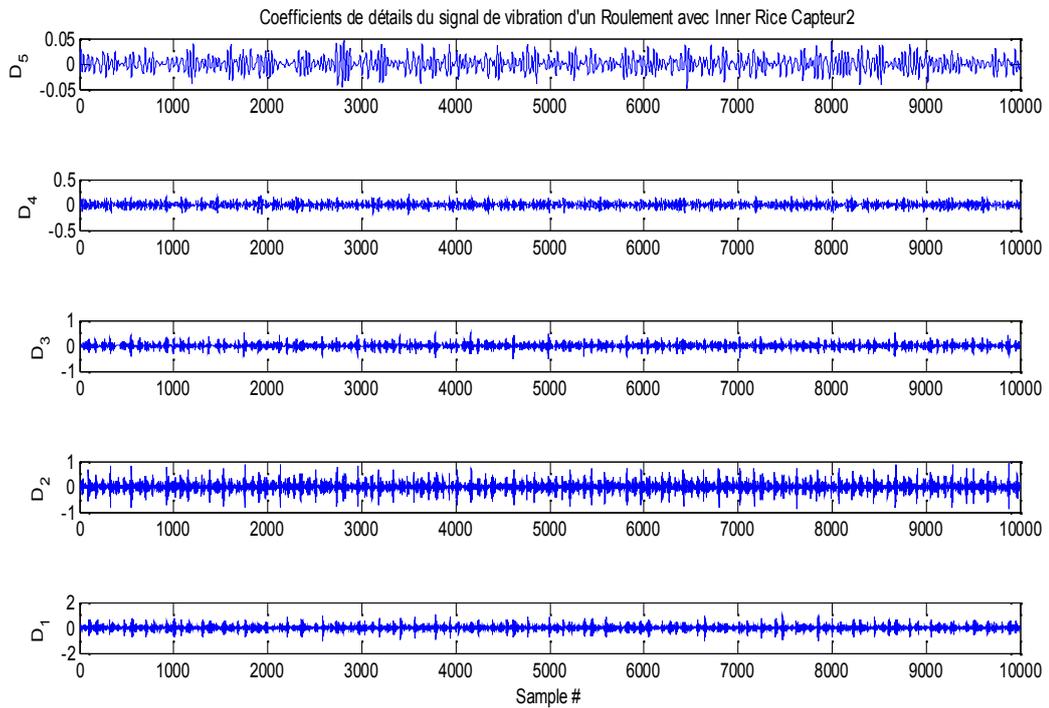


Figure 5.13 Coefficients de détail (niveau 5) avec un défaut inner rice du Capteur #02

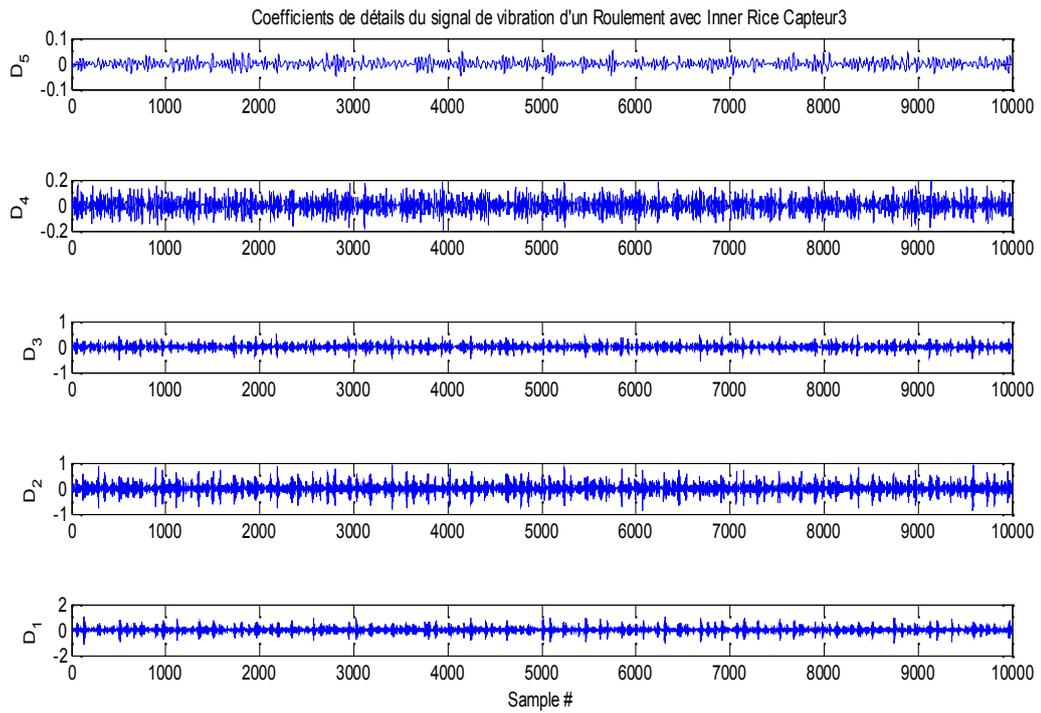


Figure 5.14 Coefficients de détail (niveau 5) avec un défaut inner rice du Capteur #03

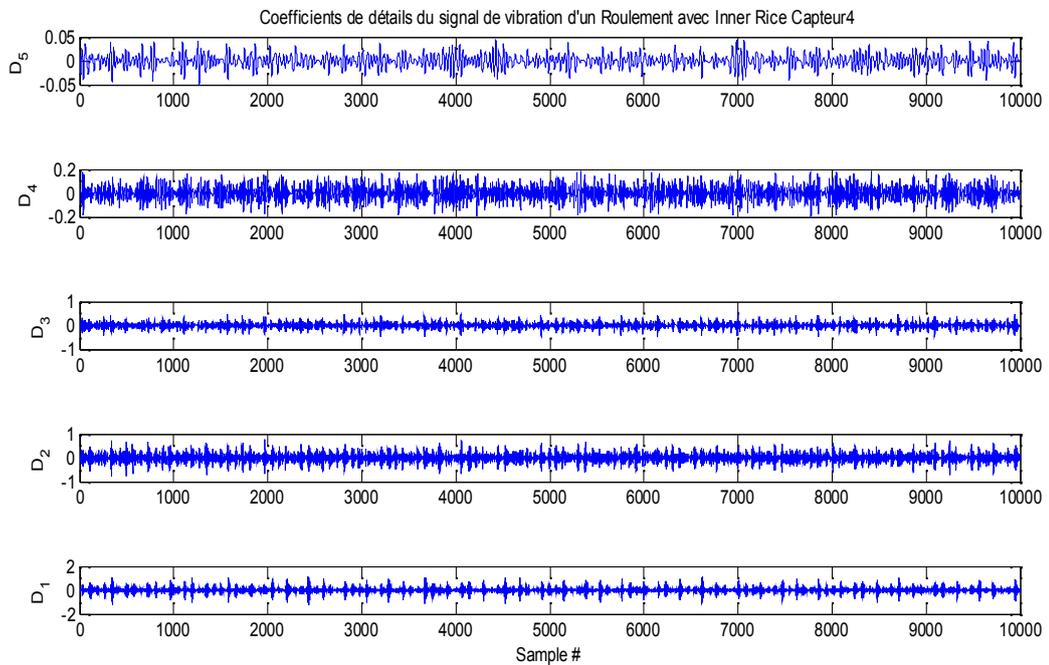


Figure 5.15 Coefficients de détail (niveau 5) avec un défaut inner rice du Capteur #04

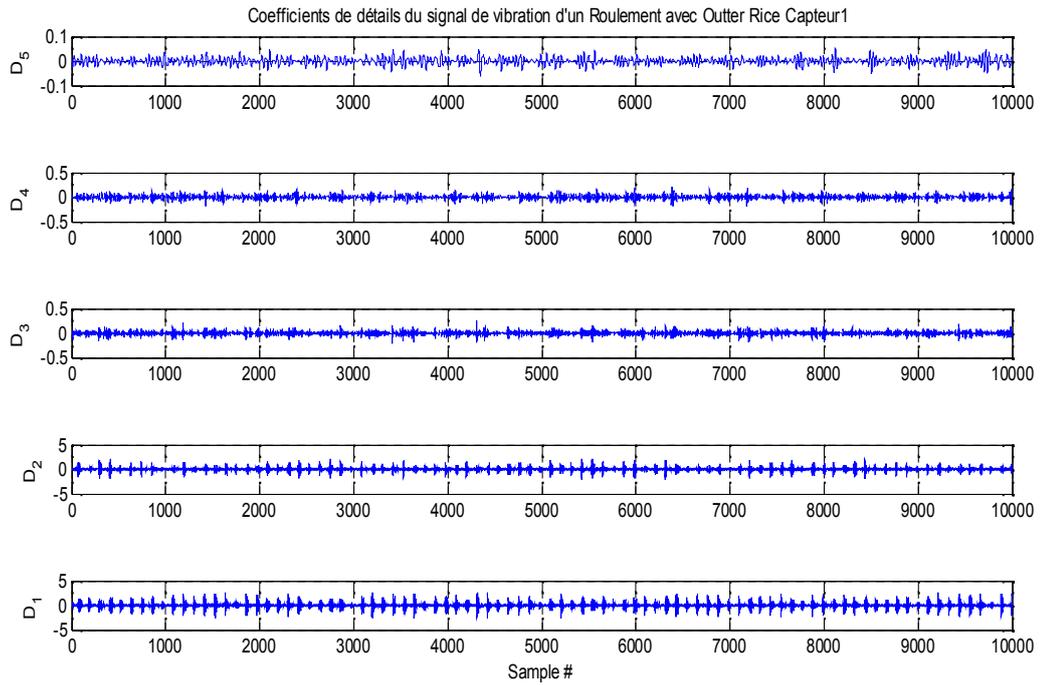


Figure 5.16 Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #01

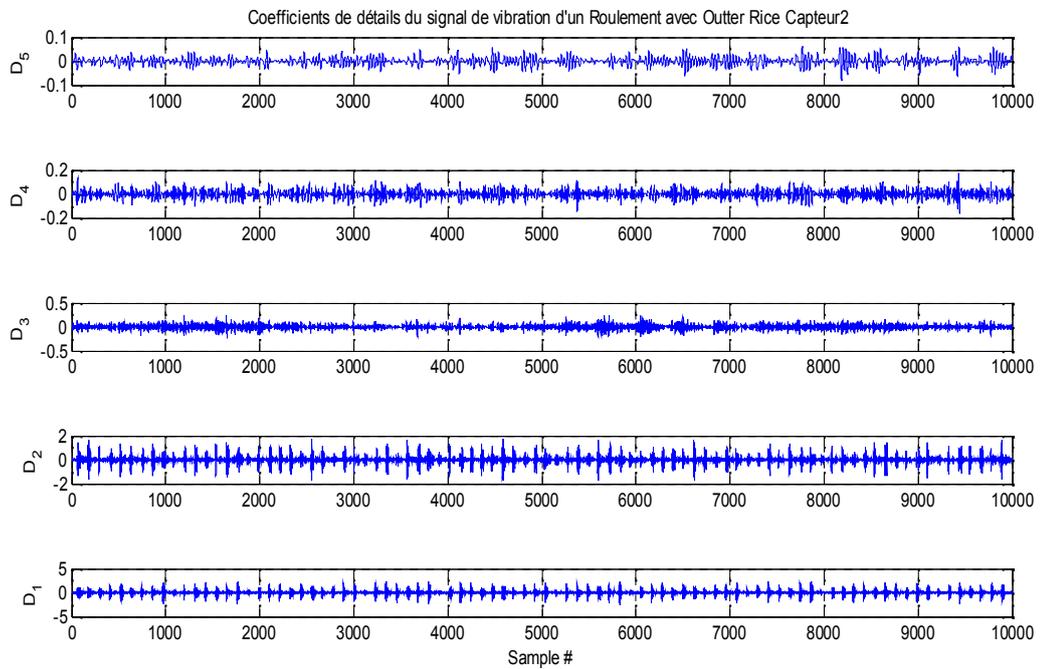


Figure 5.17 Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #02

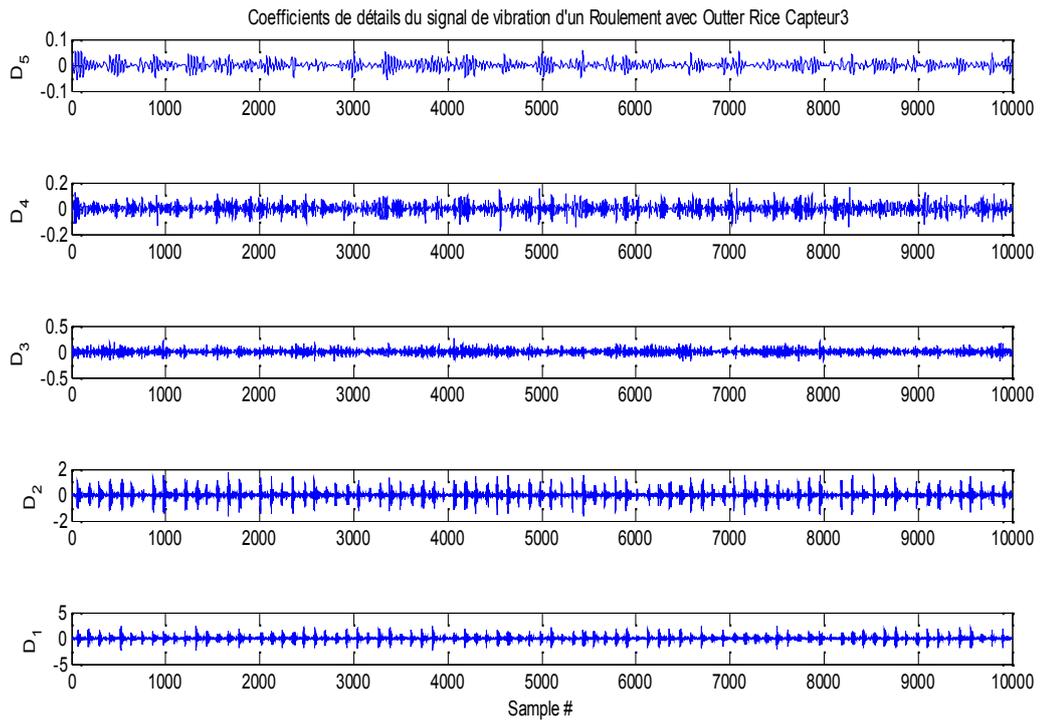


Figure 5.18 Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #03

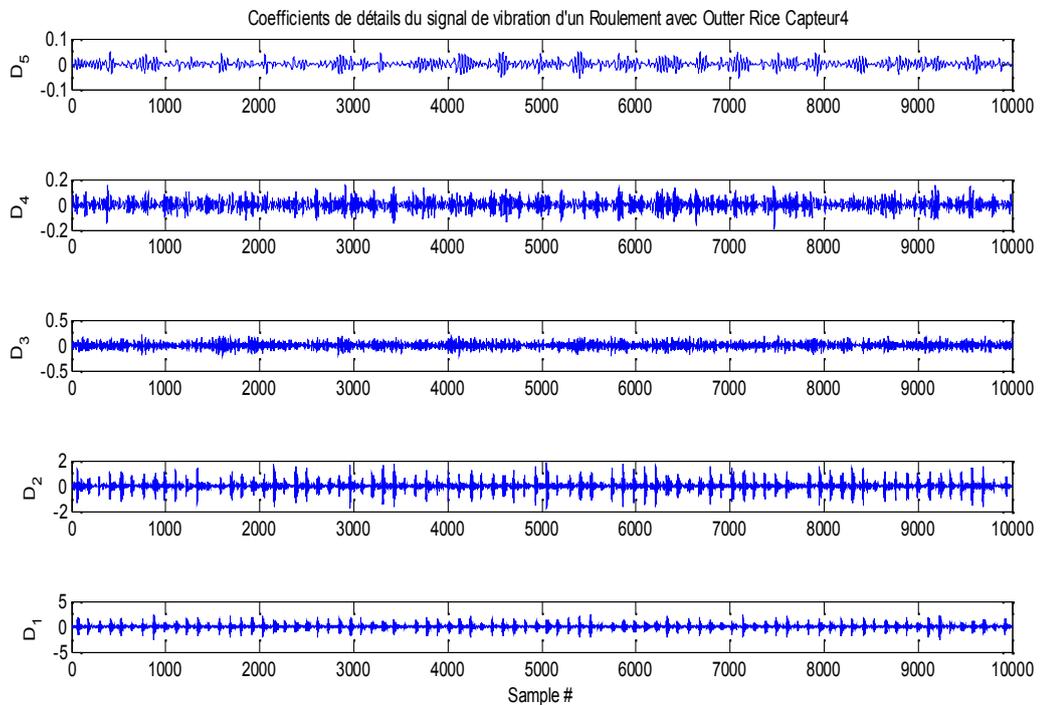


Figure 5.19 Coefficients de détail (niveau 5) avec un défaut outer rice du Capteur #04

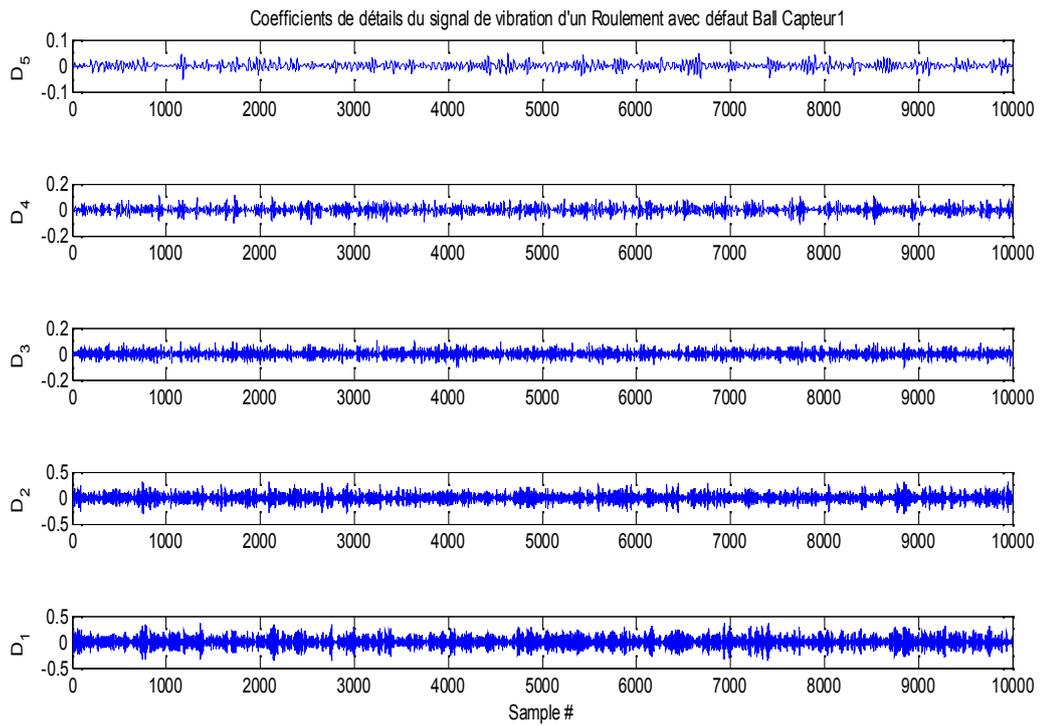


Figure 5.20 Coefficients de détail (niveau 5) avec un défaut de Balle du Capteur #01

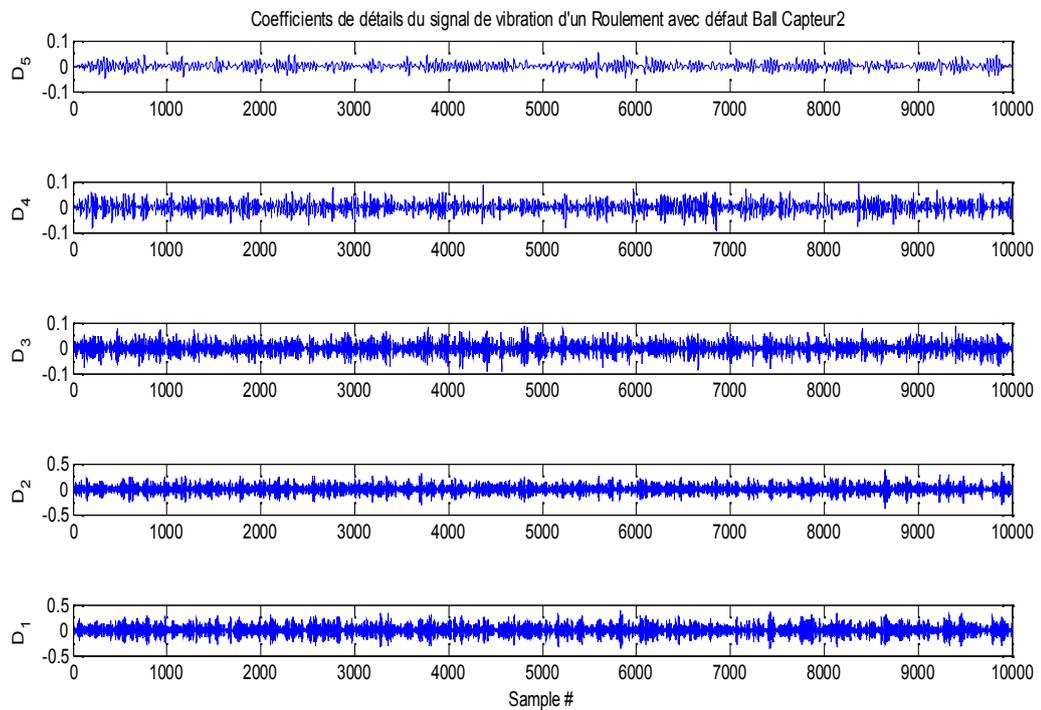


Figure 5.21 Coefficients de détail (niveau 5) avec un défaut de Balle du Capteur #02

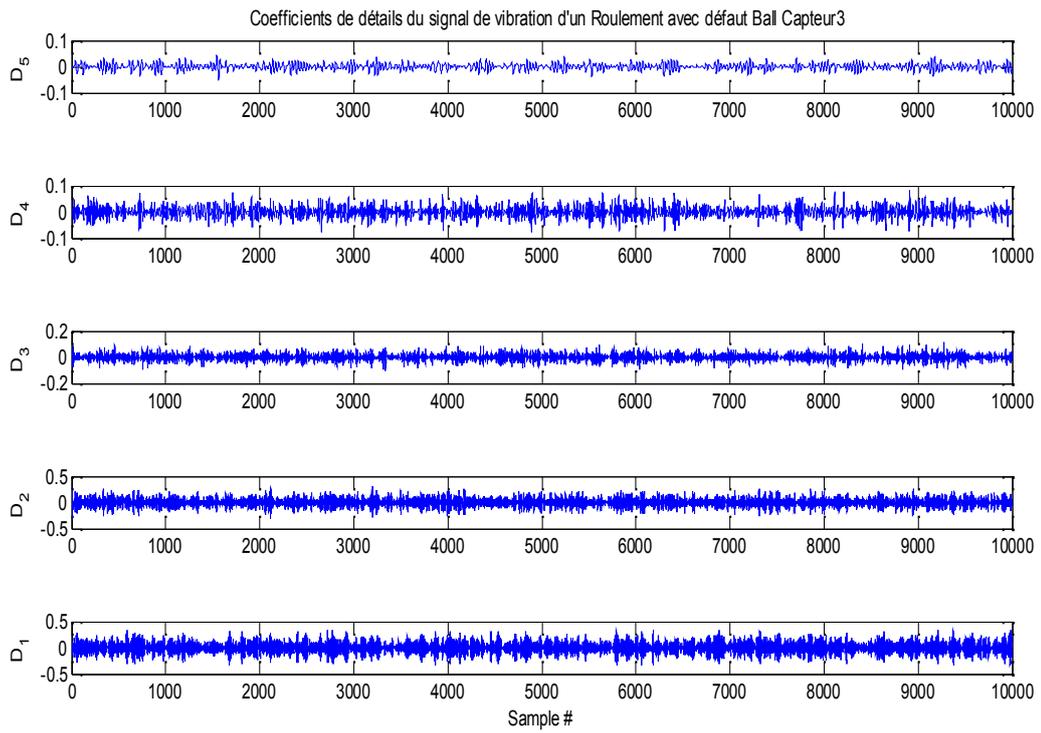


Figure 5.22 Coefficients de détail (niveau 5) avec un défaut de Balle du Capteur #03

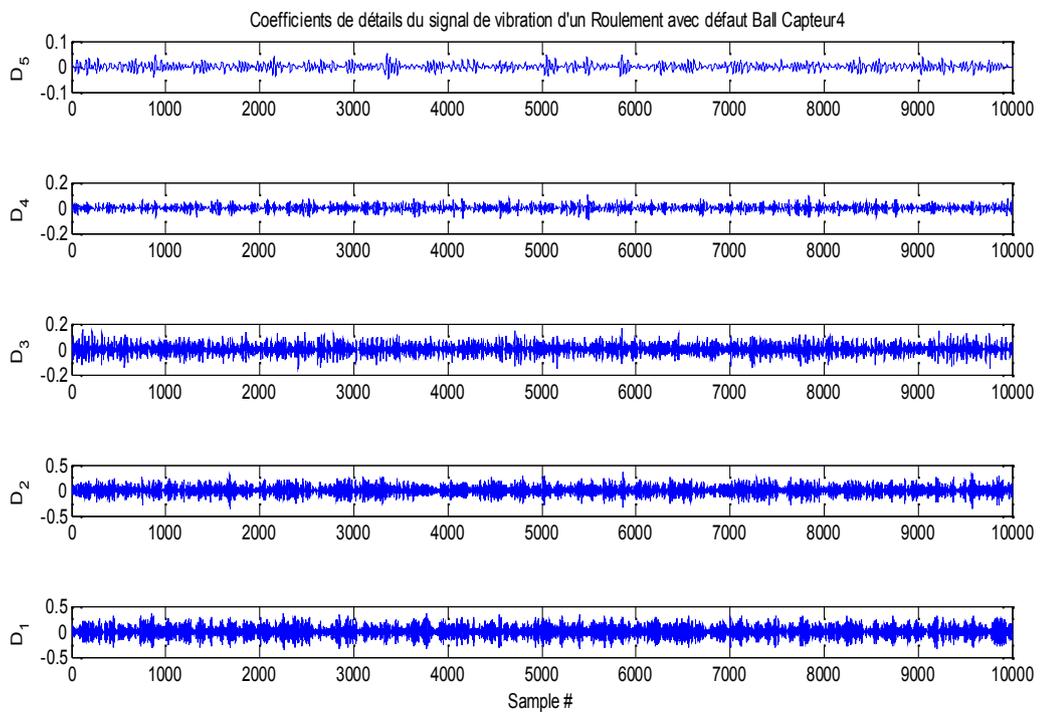


Figure 5.23 Coefficients de Détail (niveau 5) avec un défaut de Balle du Capteur #04

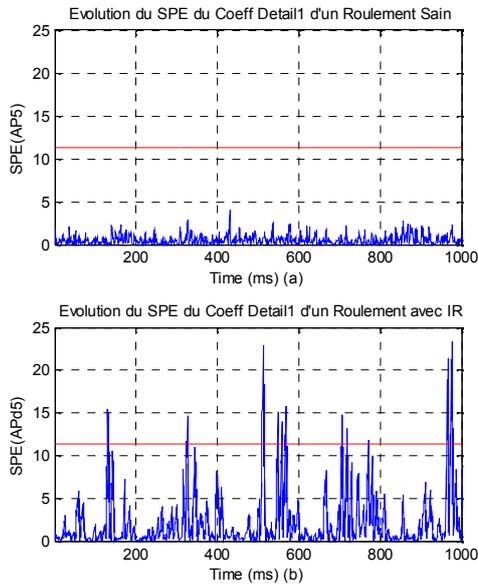


Figure 5.24 Evolution du SPE (D1)
a) neuf b) défaut IR

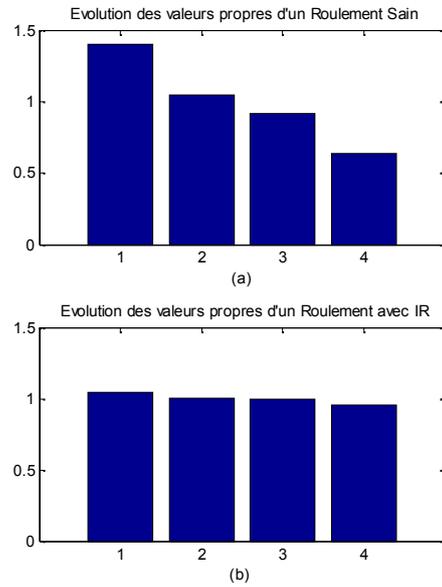


Figure 5.25 Evolution des Valeurs Propres (D1)
a) neuf b) défaut IR

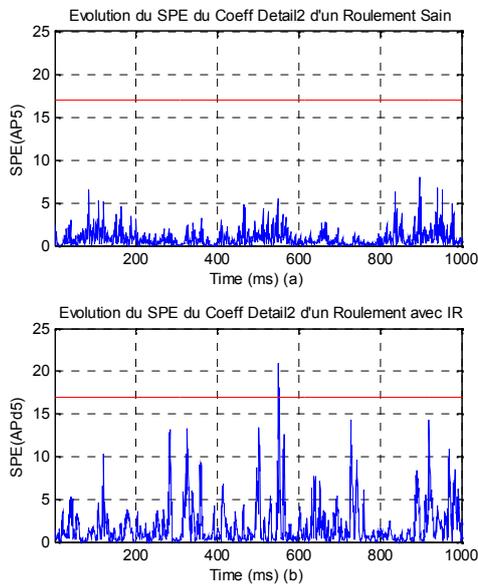


Figure 5.26 Evolution du SPE (D2)
a) neuf b) défaut IR

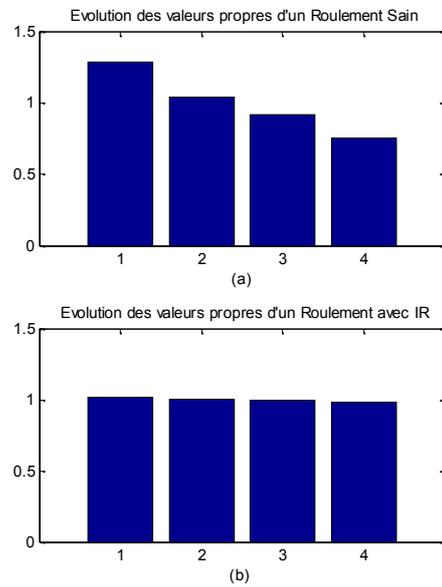


Figure 5.27 Evolution des Valeurs Propres (D2)
a) neuf b) défaut IR

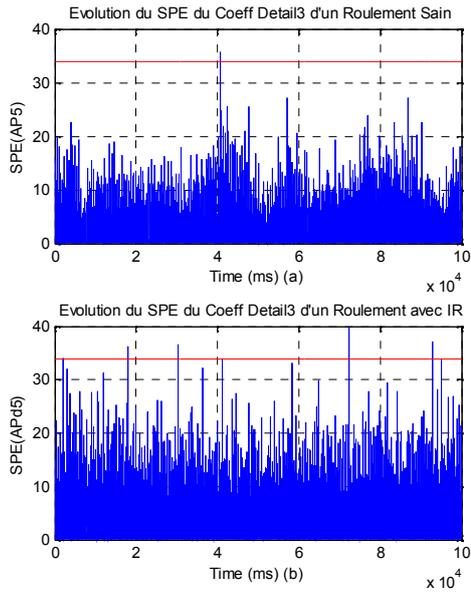


Figure 5.28 Evolution du SPE (D3)
a) neuf b) défaut IR

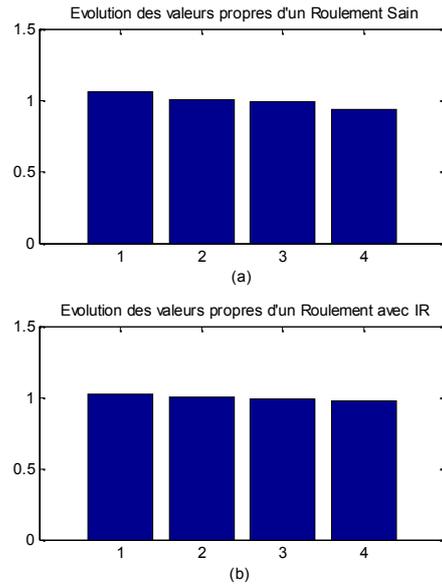


Figure 5.29 Evolution des Valeurs Propres (D3)
a) neuf b) défaut IR

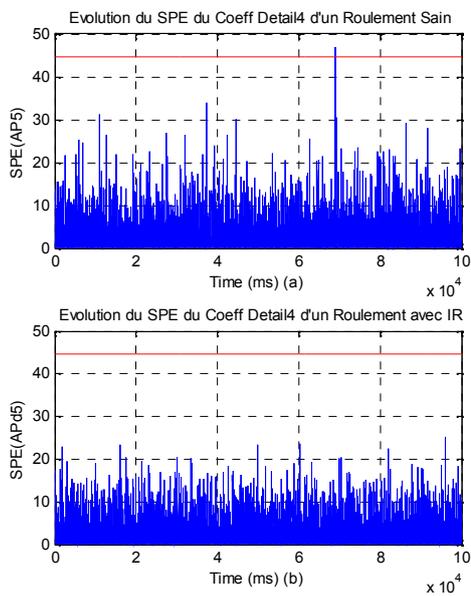


Figure 5.30 Evolution du SPE (D4)
a) neuf b) défaut IR

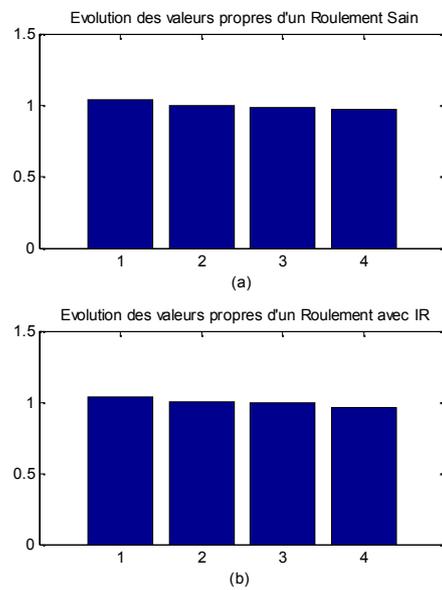


Figure 5.31 Evolution des Valeurs Propres (D4)
a) neuf b) défaut IR

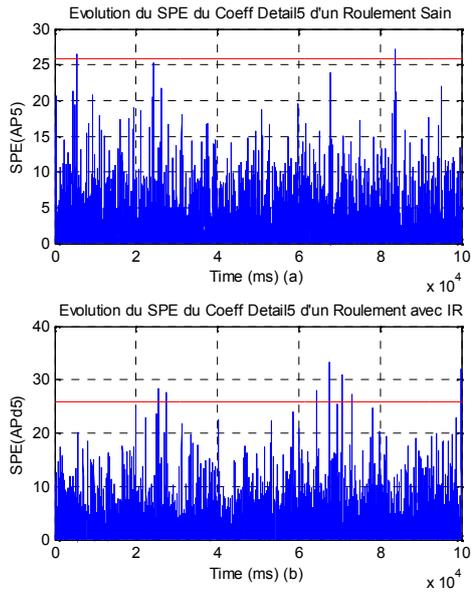


Figure 5.32 Evolution du SPE (D5)
a) neuf b) défaut IR

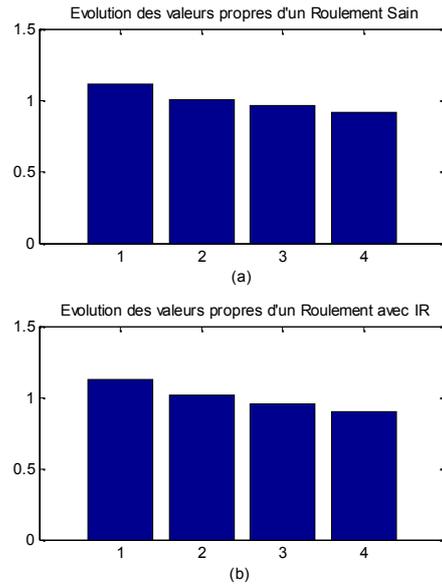


Figure 5.33 Evolution des Valeurs Propres (D5)
a) neuf b) défaut IR

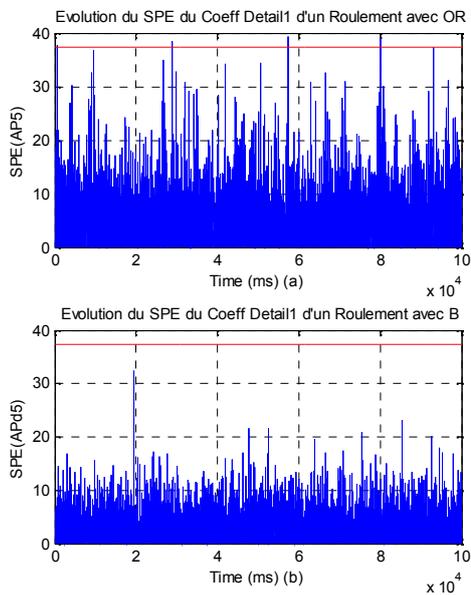


Figure 5.34 Evolution du SPE (D1)
a) défaut OR b) défaut de Ball

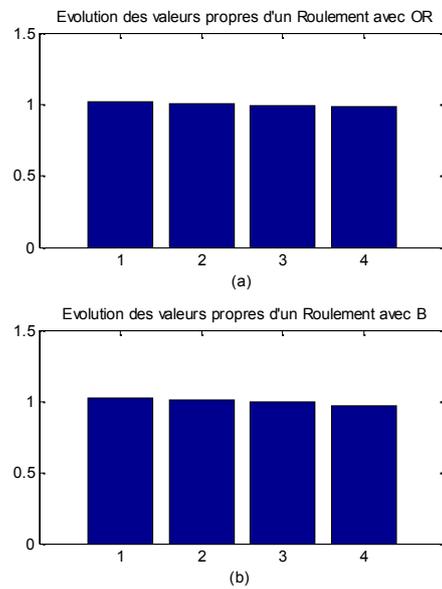


Figure 5.35 Evolution des Valeurs Propres (D1)
a) défaut OR b) défaut de Ball

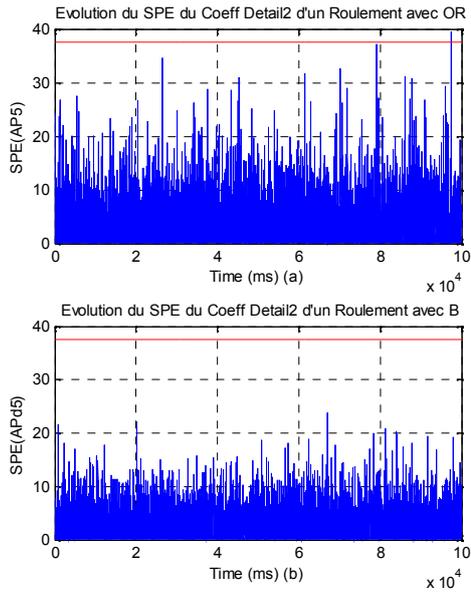


Figure 5.36 Evolution du SPE (D2)
a) défaut OR b) défaut de Ball

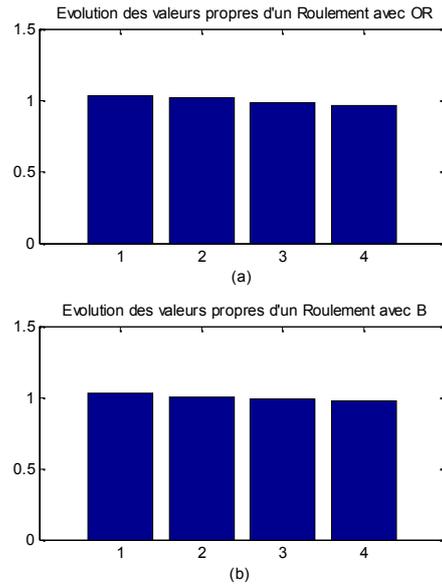


Figure 5.37 Evolution des Valeurs Propres (D2)
a) défaut OR b) défaut de Ball

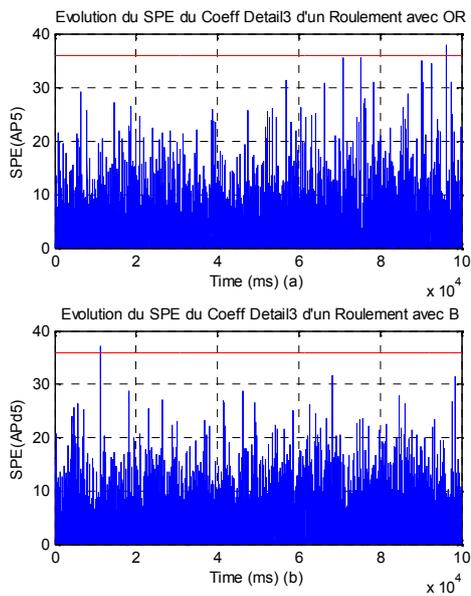


Figure 5.38 Evolution du SPE (D3)
a) défaut OR b) défaut de Ball

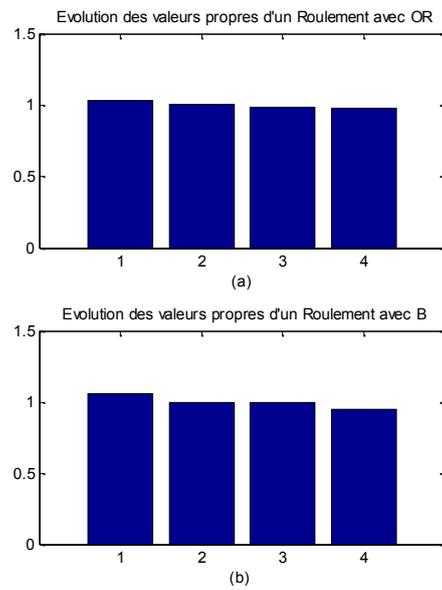


Figure 5.39 Evolution des Valeurs Propres (D3)
a) défaut OR b) défaut de Ball

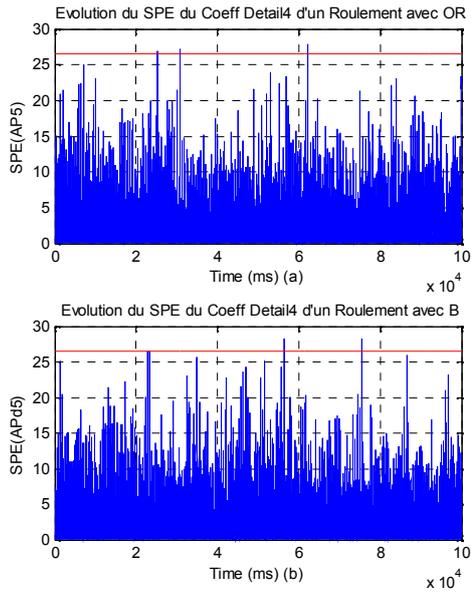


Figure 5.40 Evolution du SPE (D4)
a) défaut OR b) défaut de Ball

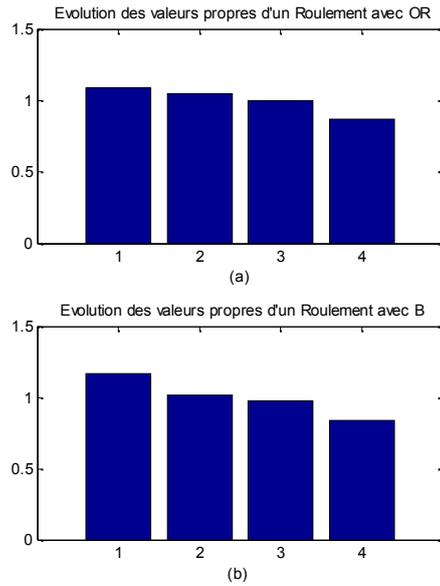


Figure 5.41 Evolution des Valeurs Propres (D4)
a) défaut OR b) défaut de Ball

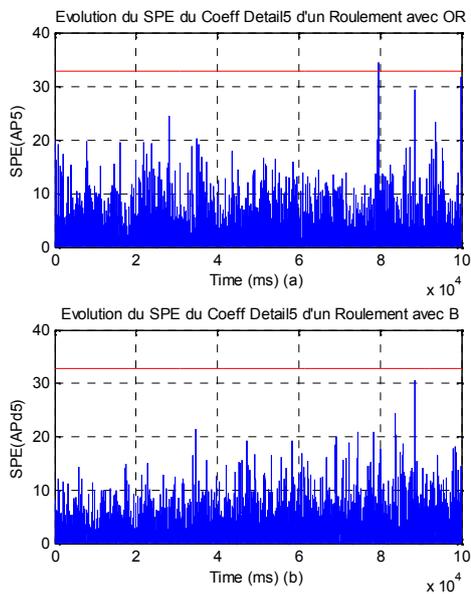


Figure 5.42 Evolution du SPE (D5)
a) défaut OR b) défaut de Ball

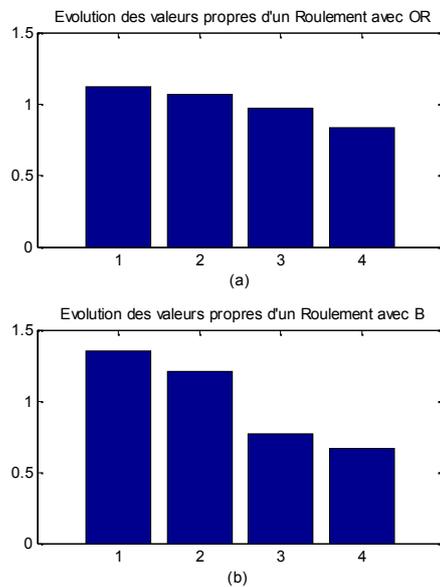


Figure 5.43 Evolution des Valeurs Propres (D5)
a) défaut OR b) défaut de Ball

5.1.5 Conclusion

Dans cette technique, nous avons présenté l'analyse en composante principale multi-échelle (MSPCA) en vue de réduire la dimension des données et détecter les anomalies se trouvant dans les roulements. Le réseau MSPCA est alimenté par les coefficients de détail et d'approximation de la DWT. Le niveau de décomposition adopté est de l'ordre du niveau 5. L'application de l'ACP nous a permis de retenir que trois (03) composantes, le quatrième capteur constitue une redondance matérielle. Une conclusion relative à la disposition des capteurs. Cette méthode peut nous renseigner non seulement sur la présence du défaut mais aussi sur la variable la plus polluante et la plus affectée. Ceci peut se faire en calculant la contribution de chaque variable retenue. La détection du défaut est testée par rapport à un seuil de 95% de l'amplitude maximale d'un roulement sain. Si la SPE est au-dessous des 95% de l'amplitude maximale du signal de vibration, le roulement est neuf, cependant si la SPE viole ce seuil, nous pouvons indiquer une situation anormale.

Cette étude nous a permis de réaliser une détection précoce et rapide, car même la décomposition à un seul niveau permet de discriminer entre un cas sain et défectueux.

5.2 Application 2 : Banc d'essai « Système à trois réservoirs »

5.2.1 Introduction

Cette application porte sur un modèle non linéaire multivariables d'un procédé hydraulique expérimental, appelé station DTS-200 illustré sur la figure 5.44 [2].



Figure 5.44 Station DTS-200 (three tank system)

5.2.2 Présentation du Banc d'essai

Le système expérimental est constitué de trois réservoirs reliés entre eux par trois vannes pour contrôler le transfert de fluide dans le système et trois valves de fuite, comme montré sur la figure 5.44, avec son schéma synoptique sur la figure 5.45. Deux pompes sont utilisées pour alimenter en eau les réservoirs 1 et 2, respectivement. Un capteur de pression différentielle est monté sur chaque réservoir, et deux capteurs d'écoulement sont fixés à la pompe de sortie. Ce système est régi par deux contrôleurs décentralisés PI et une carte d'acquisition NIDAQ 6024E est utilisée pour collecter les données du banc d'essai par le logiciel MATLAB. Les données recueillies de 2000 échantillons sont utilisées pour des expériences en mode sains et défectueux. Les signaux acquis sont L1, L2 et L3 représentent les niveaux dans les réservoirs 1, 2 et 3, respectivement, et Q1 et Q2 désignant le débit de sortie des pompes 1 et 2, respectivement [2].

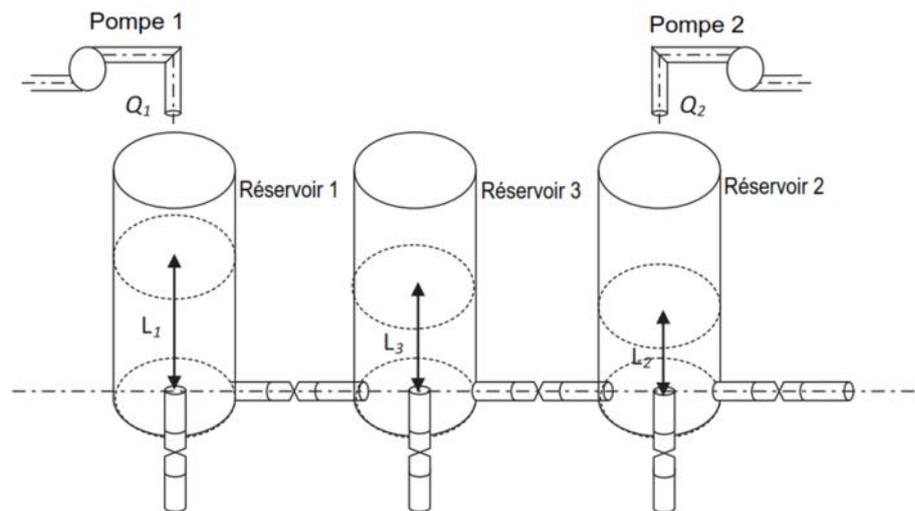


Figure 5.45 Système à trois réservoirs (three tank system)

5.2.3 Résultats expérimentaux et discussion

Pour valider la stratégie proposée et tester la capacité du BSSF, en utilisant la dissymétrie comme une mesure de la variabilité statistique, pour détecter et isoler les diverses formes de défauts, trois cas de modes de défaillance sont pris en compte:

- Cas 1, 5 % d'échec sur le capteur de débit de la pompe 1 ;
- Cas 2, 5 % d'échec sur le capteur de débit de la pompe 2 ;
- Cas 3, 1 % d'échec sur le capteur de niveau de réservoir 3 ;

ces échecs sont survenus à l'échantillon 1500.

Chaque BSSF utilise une partie des signaux de processus disponibles dans lequel ses composants sont obtenus à l'aide de l'algorithme de maximisation d'informations citées dans (§ 4.4), comme suit :

- BSSF # 1 utilise des signaux L2, L3, Q1 et Q2.
- BSSF # 2 utilise des signaux L1, L3, Q1 et Q2.
- BSSF # 3 utilise des signaux L1, L2, Q1 et Q2.
- BSSF # 4 utilise des signaux L1, L2, L3 et Q2.
- BSSF # 5 utilise des signaux L1, L2, L3 et Q1.

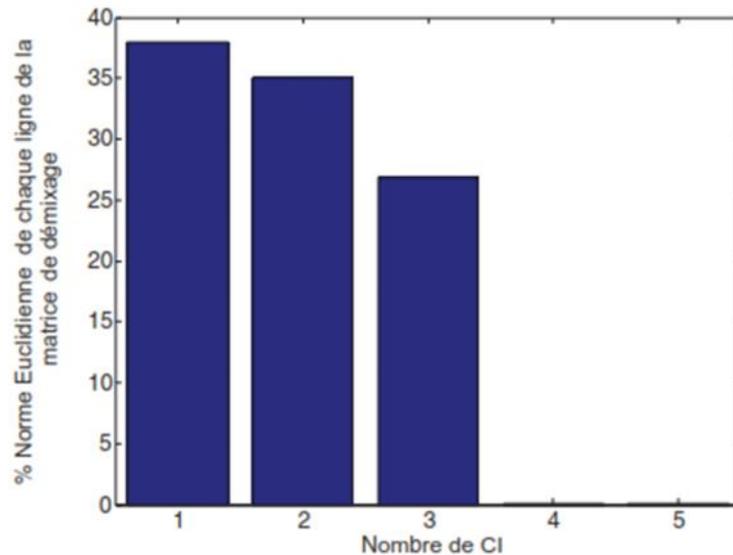


Figure 5.46 Norme euclidienne en pourcentage pour chaque matrice de séparation correspondant à chaque CI.

	Model BSS avec 4 CIs		Model BSS avec 3 CIs	
	SNR (db)	MSE	SNR (db)	MSE
L_1	67.0181	0.0004e-4	48.2951	0.0004e-2
L_2	57.3924	0.0119e-2	62.7178	0.0122e-3
L_3	85.8716	0.0051e-5	86.2144	0.0050e-5
Q_1	33.3875	0.0287	63.2821	2.0079e-3
Q_2	69.0841	1.0277e-5	39.2982	0.0121

Table 5.3 Performances de reconstruction de modèles par BSS

Avant d'appliquer ces procédures, il est nécessaire d'éliminer le bruit à partir des signaux de processus mesurés. L'approche de blanchiment est basée sur l'utilisation de BSS par laquelle les CIs dominantes peuvent être extraites. Les CIs sont triés en fonction de la norme euclidienne des lignes de la matrice de séparation et de leur contribution dans tous les signaux. En outre, le SNR et la MSE de chaque canal de mesure ont été pris en compte pour ce choix de CI dominante. La figure 5.46 fournit un terrain de représentation du pourcentage de la matrice de séparation triés W contre le numéro IC de la norme euclidienne. La matrice de séparation triée est obtenue à partir du mode de fonctionnement normal du banc d'essai DTS- 200, système à trois réservoirs. Notez que les normes euclidiennes des deux dernières CIs sont beaucoup plus petites que les autres, indiquant une rupture entre les trois premières CIs et les deux autres. Le pourcentage de la norme euclidienne de la quatrième et cinquième rangées de la matrice de séparation sont 0,1127 % et 0,0496 %, respectivement. Pour l'analyse

des performances de l'atténuation de bruit de la technique BSS, on utilise deux critères définis par les équations (4.12) et (4.13). Ces critères sont appliqués à des modèles de BSS de dimension trois et quatre CIs retenus.

Les résultats globaux pour les deux modèles de BSS sont résumés dans le tableau 5.3. Le tableau montre clairement que la performance des atténuations de bruit des deux modèles BSS est particulièrement efficace. En outre, il est raisonnable de croire que les divergences entre les performances du premier et deuxième modèle BSS peuvent être mesurées par le SNR qui augmente la plupart des signaux du processus dans lequel le MSE est également réduite. L'évaluation de la performance des deux filtres utilisant le même ensemble de signaux du processus est fourni par les capacités parfaites des filtres pour éliminer le bruit et retourner les signaux non corrompus ; par conséquent, il est intéressant de comparer les signaux reconstruits par les modèles BSS envisagés en utilisant un SNR et une MSE. Cependant, il est très difficile de choisir un modèle de BSS dans lequel les deux critères sont presque similaires. Sur la base de la moyenne arithmétique du SNR et MSE, le premier modèle BSS (à 4 CIs) est remarquablement plus précis en termes de SNR et MSE. Par conséquent, le modèle construit sur la base des CIs comprend quatre CIs.

La figure 5.47 décrit les composantes indépendantes de chaque BSSF en mode sain. Le tableau 5.4 présente la dissymétrie de chaque composante du BSSF dans la situation de fonctionnement normal d'un système à trois réservoirs.

La figure 5.48 illustre les différentes composantes indépendantes du banc du BSSF dans le cas 1. Lors de l'apparition du défaut, toutes les composantes des BSSFs qui ont été touchées ne peuvent être vues à partir des graphiques. Cet effet n'a pas été très important sur les signaux de source. Toutefois, lorsque le défaut sur le système est assez petit ou le système est contrôlé par des contrôleurs appropriés; l'évolution de la courbe de chaque signal n'est pas claire et que nous ne pouvons pas détecter le défaut sur la figure en question. Le tableau 5.5 contient la dissymétrie de chaque composante de chaque BSSF. Le défaut est détecté quand la dissymétrie des signaux de BSSF est différente aux signaux de BSSF correspondants à l'état normal. Chaque valeur en gras dans les tableaux (5.5-5.7) indique le défaut produit. Ce changement dans la dissymétrie est essentiellement dû à l'une des données incorrectes fournies par la mesure du capteur de débit de la pompe 1. Ceci affecte les caractéristiques statistiques de toutes les composantes du BSSF qui comprennent le signal Q1. La colonne e couleur (qui n'est pas en gras) dans le tableau 5.5 présente les mêmes caractéristiques statistiques de toutes les composantes du BSSF # 4 qui sont calculées sans le signal Q1. Par conséquent, le défaut est clairement dû au capteur de débit de la pompe 1.

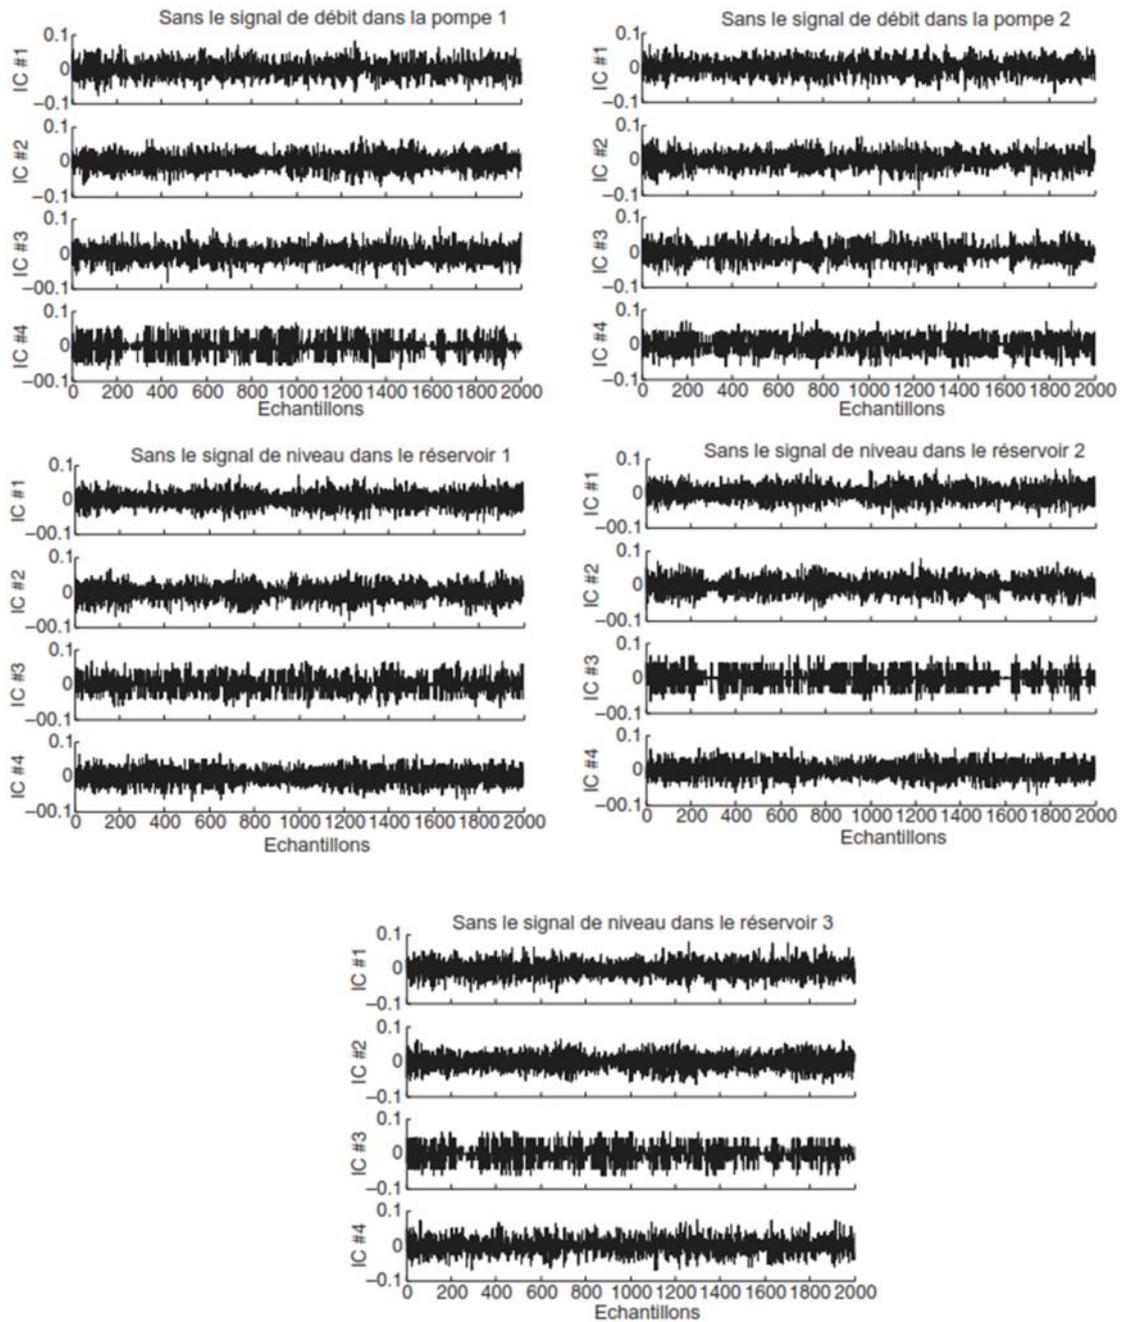


Figure 5.47 Les composantes indépendantes des filtres BSS en mode normal (sain).

	BSSF #1	BSSF #2	BSSF #3	BSSF #4	BSSF #5
IC #1	-0.0173	0.0504	0.0555	-0.0016	0.0977
IC #2	-0.0987	0.0808	-0.1578	-0.0883	-0.0800
IC #3	-0.0513	0.0135	0.1351	-0.0151	0.0655
IC #4	0.0367	0.0277	0.0325	-0.1083	-0.0234

Table 5.4 La dissymétrie des composants des BSSF des variables du système expérimental dans l'état normal.

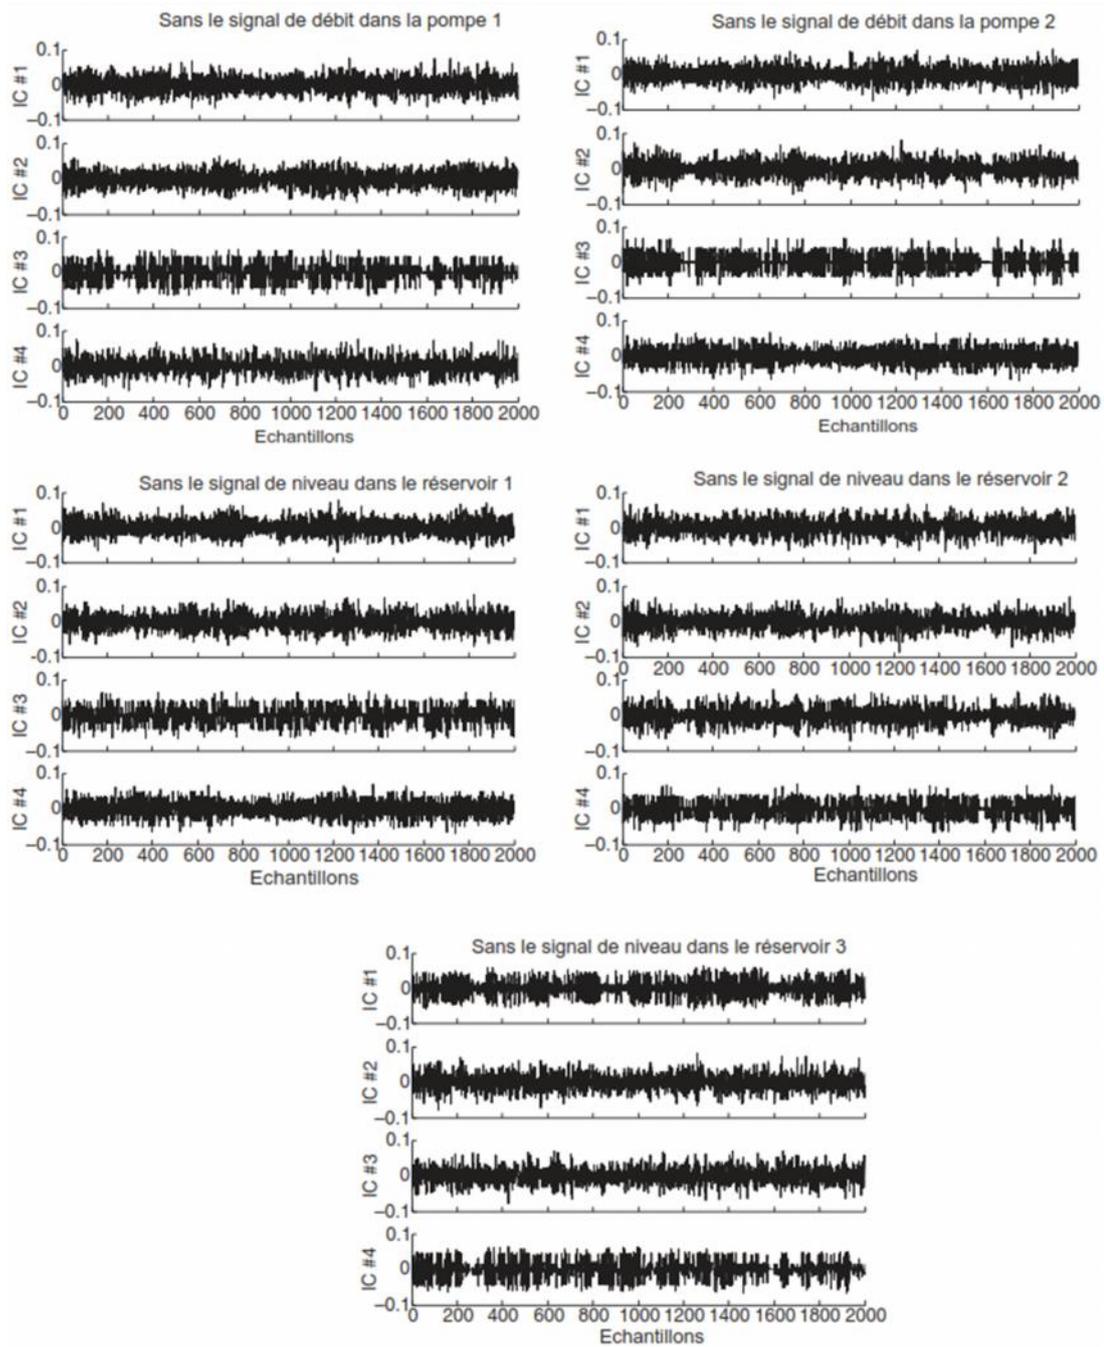


Figure 5.48 Les composantes indépendantes des filtres BSS dans le cas 1.

	BSSF #1	BSSF #2	BSSF #3	BSSF #4	BSSF #5
IC #1	-0.0197	0.0462	0.1590	-0.0016	-0.0643
IC #2	-0.0990	0.0677	-0.0407	-0.0883	0.0334
IC #3	-0.0539	0.0269	-0.1418	-0.0151	0.0530
IC #4	0.0380	0.0267	0.0351	-0.1083	-0.0345

Table 5.5 La dissymétrie des composants des BSSF des variables du système expérimental avec défaut, cas 1.

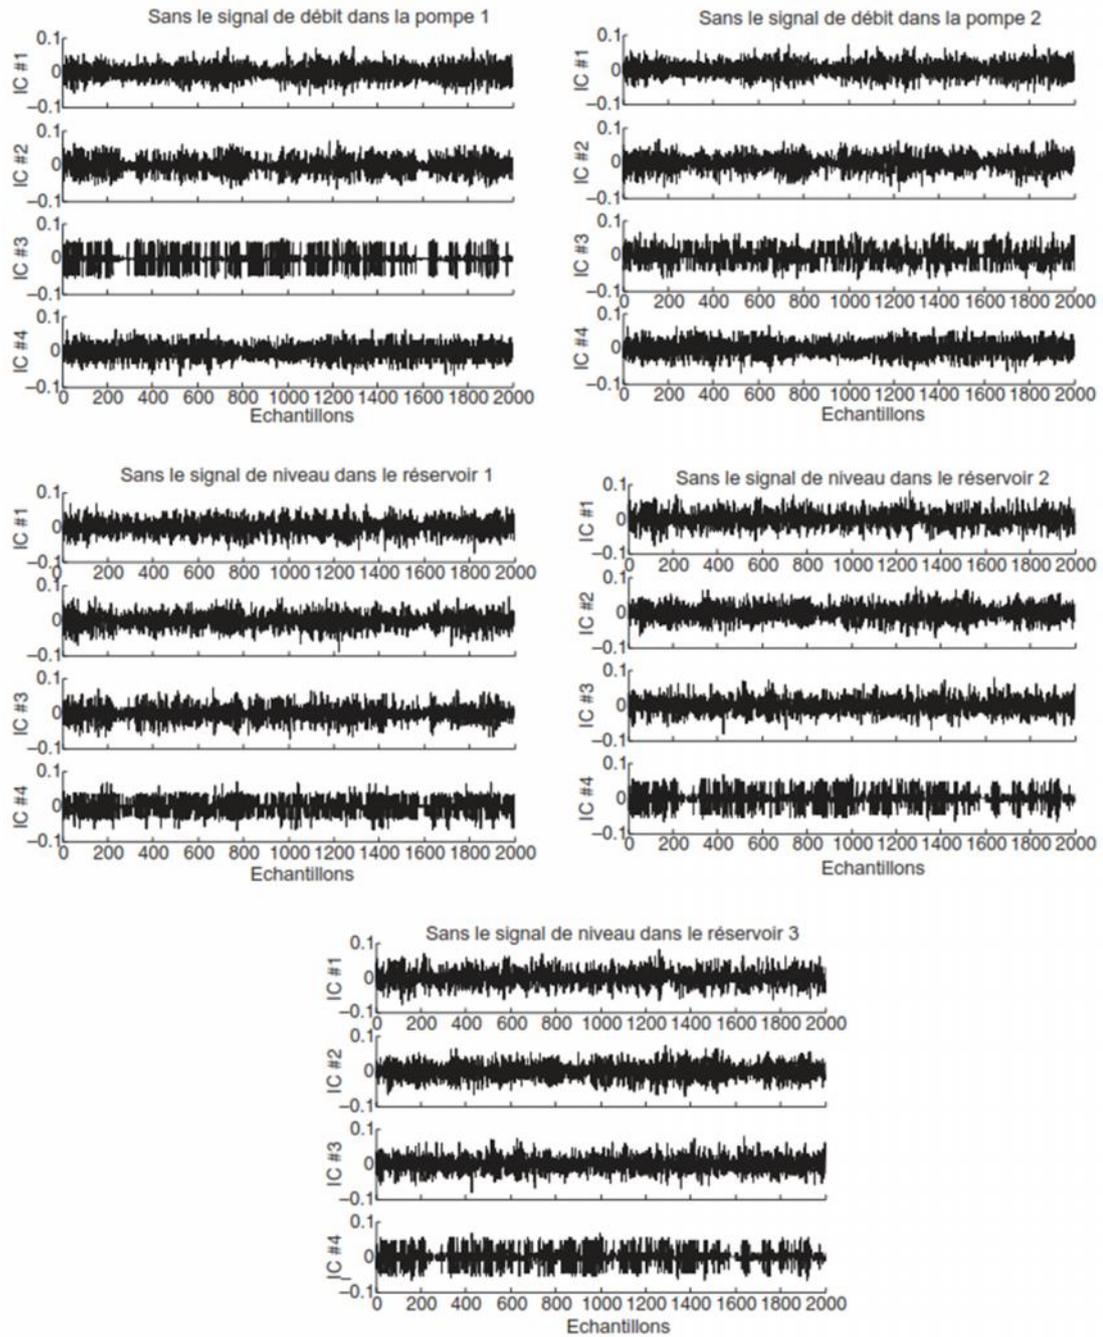


Figure 5.49 Les composantes indépendantes des filtres BSS dans le cas 2.

	BSSF #1	BSSF #2	BSSF #3	BSSF #4	BSSF #5
IC #1	-0.0212	0.0691	0.0551	0.0004	0.0977
IC #2	-0.0970	0.0935	0.1578	0.0886	-0.0800
IC #3	-0.0514	-0.0053	0.1349	-0.0137	0.0655
IC #4	0.0406	0.0356	0.0325	-0.1166	-0.0234

Table 5.6 La dissymétrie des composants des BSSF des variables du système expérimental avec défaut, cas 2.

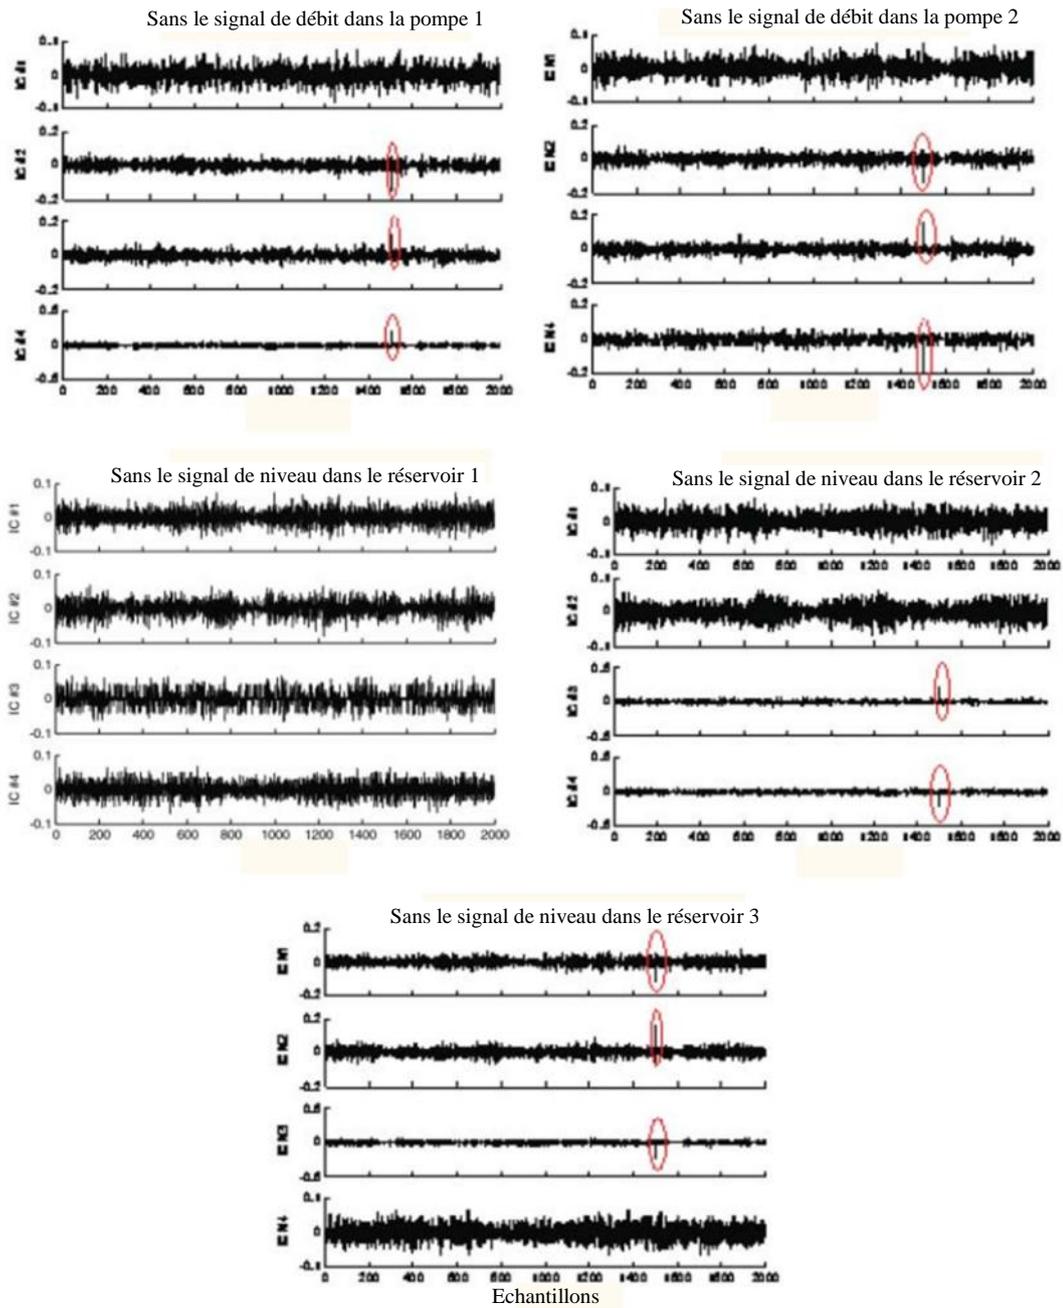


Figure 5.50 Les composantes indépendantes des filtres BSS dans le cas 3.

	BSSF #1	BSSF #2	BSSF #3	BSSF #4	BSSF #5
IC #1	0.0284	-0.0299	0.0555	-0.0097	0.0746
IC #2	-0.1106	0.2460	-0.1578	-0.1522	-0.2699
IC #3	0.5380	-0.4646	0.1351	0.1674	0.1019
IC #4	-0.4158	0.0357	0.0325	0.4207	-0.4498

Table 5.7 La dissymétrie des composants des BSSF des variables du système expérimental avec défaut, cas 3.

Les résultats du cas 2 sont présentés dans la figure 5.49. A partir de ces courbes, il est très difficile de voir un changement brusque. Cependant, il n'est pas possible d'attribuer le défaut à un signal de processus spécifique. Ainsi, le défaut est mélangé dans toutes les composantes reconstruites du BSSF. Le tableau 5.6 résume la dissymétrie de chaque composante pour chaque BSSF où les valeurs en gras indiquent la présence de défauts. La colonne de couleur montre l'objet du changement des caractéristiques statistiques.

La figure 5.50 décrit les composantes de BSSF dans lequel le défaut est détecté. Le changement brusque dans les composantes indépendantes de BSSF est marqué par des cercles rouges. Le moment de l'apparence du changement représente le moment de l'apparition du défaut. Dans ce cas, le niveau 3 (L3) n'a pas d'influence sur les autres variables du processus. Le niveau dans le réservoir 3 n'est pas contrôlable ce qui représente l'interaction entre les variables du système de sortie et d'entrée. Par conséquent, les caractéristiques statistiques sont modifiées dans les signaux de BSSF du système qui sont l'objet du défaut (tableau 5.7).

5.2.4 Conclusion

La méthode proposée a prouvé son efficacité et que la sensibilité de la technique du FDI à des changements dans les composantes indépendantes est basée sur la décomposition aveugle. Cette méthode basée sur le banc BSSF, en utilisant l'analyse de données et sans connaissance du modèle de processus, peut indiquer avec précision la présence et la cause de la panne.

L'indice de détection de défaut sur la base de la dissymétrie des composants de BSSF est capable de surmonter le problème de la détection des défauts de capteur. Les résultats montrent également que la dissymétrie peut, dans différentes situations, détecter les changements dans les trois variables du système de réservoir expérimentales. Il est également important de noter la grande sensibilité de la dissymétrie dans la détection de défauts avec faibles amplitudes.

Enfin, les résultats expérimentaux présentés confirment la capacité du diagnostic de défauts à base des banc BSSF pour caractériser les incertitudes et les imprécisions de traiter et surmonter les difficultés associées à la détection de défauts de capteurs et d'isolement dans les systèmes complexes présents dans un environnement stochastique.

Ces résultats ont été publiés dans une revue de renommée établie [3].

5.3 Références bibliographiques

- [1] BANC D'ESSAI : *Case Western Reserve University Bearing Data Center Website*: <http://csegroups.case.edu/bearingdatacenter/home>
- [2] AMIRA-DTS200. Laboratory Setup Three Tank System. Amira Gmbh, Duisburg, 1996.
- [3] A. Kouadri, K. Baiche, M. Zelmat, *Blind source separation filters-based-fault detection and isolation in a three tank system*, Journal of Applied Statistics, février 2014, link : <http://dx.doi.org/10.1080/02664763.2014.891570>.

Conclusion générale

Les processus industriels complexes nécessitent une méthodologie de détection rapide et précoce de leurs défaillances à cause de leurs utilisations fréquentes dans diverses applications et leur impact socio-économique. Le travail présenté dans cette thèse porte sur plusieurs approches de traitement et d'analyse de données appliquées au diagnostic des défauts des procédés industriels.

Pour mettre en œuvre ce travail de recherche, nous avons tracé la suivantes :

- Procéder à un état de l'art sur le principe du FDI et les différents défauts pouvant être enregistrés et identifiés.
- Etablir un prétraitement basé sur l'analyse spectrale avec modèle et sans modèle en utilisant les statistiques d'ordre deux et d'ordre supérieur.
 - ✓ le premier type d'approche consiste à utiliser des modèles analytiques du processus, ceux-ci fournissent une estimation en ligne des grandeurs non mesurables.
 - ✓ la seconde catégorie d'approche consiste à analyser les signaux mesurés sur la machine en cours de fonctionnement. Les analyses sont réalisées pour la plupart, dans le domaine fréquentiel et en régime permanent, les informations issues de ces analyses permettent souvent une identification efficace de défaillances présentes au niveau des différents organes du processus. Toutefois ces approches fréquentielles trouvent leurs limites en présence d'importants bruits de mesure qui noient l'information pertinente.
- Réaliser un test statistique basé sur la SPE en utilisant la MSPCA,
- Identifier les sources de défaillance en utilisant l'ACI.

Durant la phase d'analyse, nous avons utilisé aussi la décomposition en ondelettes (DWT) sachant que les défauts (traités) ont un caractère haute fréquence. A cet effet, nous avons considéré les coefficients de détails comme étant porteurs d'informations. Ce choix est justifié par le fait que les signaux de vibration ont un comportement non stationnaire, d'où l'incompétence de l'analyse classique basée sur la FFT pour extraire des informations pertinentes. Le choix de la fonction « db4 » est justifié en supposant que les défauts des roulements ont une dynamique très rapide.

Ensuite, nous avons appliqué les coefficients de détails d'ondelettes aux entrées de la MSPCA. Les signaux de défauts sont décomposés en approximations et détails. La contribution de chaque échelle est rassemblée dans des matrices séparées, la nature de multi-

échelle de MSPCA est convenable pour travailler avec des données de la machine qui sont typiquement non stationnaires et représentent l'effet cumulatif de beaucoup de phénomènes de machine.

L'identification des sources des défauts est assurée en utilisant l'analyse en composante indépendante basée sur la méthode de séparation aveugle des sources. Par ailleurs, nous sachons que l'acquisition des signaux par des capteurs constitue toujours un mélange de signaux de plusieurs sources. Notre intérêt majeur est de détecter le défaut ainsi que son identification. Pour ce faire, la solution proposée est d'utiliser l'analyse en composantes indépendantes (ACI). Les résultats obtenus illustrent la validation de notre choix et offre un horizon prometteur dans cette optique.

Ainsi ce travail a permis de développer et de tester des outils qui peuvent contribuer efficacement au diagnostic des processus industriels.

En perspective ce travail pourrait donner lieu à des études complémentaires dans les directions suivantes :

- ✓ Elargir le nombre de défauts.
- ✓ Améliorer les méthodes utilisées en exploitant mieux les mesures pour détecter et d'isoler le défaut pour rendre le système de décision totalement adaptatif.
- ✓ Recherche de nouvelles méthodes sans modèles en particulier, utilisant les réseaux neuronaux, l'ACP non linéaire de type neuronal, réseaux d'ondelette (WNN) et etc.
- ✓ Implanter ces algorithmes de diagnostic dans des systèmes de surveillance et de maintenance industriels.