

الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'enseignement supérieur et de la recherche scientifique

Université 20 Août 1955-Skikda
Faculté de Technologie
Département : Génie Mécanique
Réf : D012118013D



جامعة 20 أوت 1955 سكيكدة
كلية التكنولوجيا
قسم: الهندسة الميكانيكية
المرجع : D012118013D

Thèse présentée en vue de l'obtention Du diplôme de : Doctorat en sciences

Filière :

Génie Mécanique

Spécialité : **Mécatronique**

Présentée par :

RAMDANE ADLENE

Analyse et diagnostic robuste d'un système Mécatronique Par l'approche Bond Graph

Soutenu publiquement le : 24 / 06 / 2018

Devant le Jury composé de :

Président : Dr. MEHENAOU LAMINE

M.C. A Université Skikda

Rapporteur : Pr. LACHOURI ABDERRAZAK

Professeur Université Skikda

Examineurs :

Dr. KECHIDA SIHEM

M.C. A Université Guelma

Dr. ZAHZOUH ZOUBIR

M.C. A Université Souk Ahras

Dr. BENCHOUIA NEDJEM EDDINE

M.C. A Université Souk Ahras

Année Universitaire : 2017 / 2018

Table Des Matières

SOMMAIRE	I
PAGE DE GARDE	II
TABLE DES MATIERE	III
REMMERCIEMENT	IV
DEDICACES	V
RESUMES	VI
LISTE DES FIGURES	VII
LISTE DES TABLEAUX.....	VIII
NOTATIONS ET SYMBOLES	IX
INTRODUCTION GENERALE	1
CHAPITRE 1 : Etat de l'art Sur Les Méthodes De Diagnostic Des Défauts	7
1.1. Introduction	7
1.2. Dispositif se sureté de fonctionnement	7
1.3. Attributs de la sureté de fonctionnement	8
1.3.1. Disponibilité :	8
1.3.2. Fiabilité :	9
1.3.3. Efficacité :	9
1.3.4. Sécurité-innocuité (safety) :	9
1.3.5. Maintenabilité :	9
1.4. Définition liées au diagnostic.....	9
1.4.1. Acquisition de données :	9
1.4.2. Surveillance :	9
1.4.3. Aide à la décision :	10
1.4.4. Maintenance :	10
1.4.5. Défaut (fault) :	10
1.4.6. Défaillance (faillure) :	10
1.4.7. Panne (Break-down) :	11
1.4.8. Symptôme (Symptom) :	11
1.4.9. Résidu (Résidual) :	11
1.4.10. Diagnostic :	11
1.4.11. Perturbation :	11
1.5. Procédure de diagnostic.....	12

1.6. Les différents types de défauts	12
1.6.1. Les défauts actionneurs :	13
1.6.2. Les défauts capteurs :	13
1.6.3. Les défauts composants ou systèmes :	13
1.7. Méthodes de surveillance.....	13
1.7.1. Méthodes sans modèle mathématique	14
1.7.1.1. Les méthodes dites mono-signal.....	15
1.7.1.2. Les méthodes dites multi-signal	15
1.7.2. Méthodes à base de modèle	17
1.7.2.1. Méthodes de génération des résidus	19
1.7.2.1.1. Filtre de Kalman.....	20
1.7.2.1.2. Estimation des paramètres	22
1.7.2.1.3. Estimation d'état (observateur)	23
1.7.2.2. Redondance analytique.....	24
1.7.2.3. Approche structurelle	25
1.7.2.4. Méthode G.D.E	27
1.8. Principe de la surveillance à base de modèle	27
1.9. Conclusion.....	29
Bibliographies	30
CHAPITRE 2 : Modélisation d'un Système Mécatronique Application sur un Système Eolien.....	31
2.1. Introduction	31
2.2. Concept fondamental de l'approche Bond Graph	31
2.3. Les transferts de puissance.....	32
2.4. Variables mises en jeu.....	32
2.5. Les éléments bond graphs.....	33
2.5.1. Eléments passifs simples	34
2.5.1.1. L'élément R	34
2.5.1.2. L'élément C	34
2.5.1.3. L'élément I	35
2.5.2. Eléments Actifs : les sources.....	36
2.5.2.1. Eléments de jonction	36
2.5.2.2. L'élément TF	37
2.5.2.3. L'élément GY	38

2.6. Notion de causalité	38
2.7. Procédure d'affectation de la causalité	39
2.8. Modélisation du système de production d'énergie de l'éolienne.....	39
2.8.1. Description du système	39
2.8.2. Modèle aérodynamique.....	40
2.8.3. Modèle de la partie mécanique	43
2.8.4. Backlash	47
2.8.5. Modèle de la partie électrique	48
2.8.6. La transformation de Park.....	49
2.9. Les résultats de simulations.....	51
2.9.1. Mise en œuvre du modèle de simulations.....	51
2.9.2. Paramètres du système	52
2.10. Discussions des résultats	59
2.11. Conclusion.....	59
Bibliographies	61

CHAPITRE 3 : Technique D'analyse Spectrale pour la Détection du Défaut

Bcklash.....	62
3.1. Introduction	62
3.2. Méthodes non paramétriques.....	63
3.2.1. Le périodogramme et le corrélogramme.....	63
3.2.2. Propriétés du corrélogramme	67
3.3. Méthodes paramétriques	68
3.3.1. Modèle AR (Autorégressif).....	68
3.3.2. Modèle AM (Moyenne Mobile)	69
3.3.3. Modèle ARMA (Auto Régressif à Moyenne Mobile)	70
3.4. Analyse Spectrale Haute Résolution.....	72
3.4.1. Méthode de Prony	72
3.4.2. Méthode de Pisarenko.....	75
3.4.3. Méthode de Burg pour l'estimation des paramètres.....	76
3.4.4. Méthode MUSIC	77
3.4.5. Méthode des vecteurs propres EV	77
3.4.6. Méthode de Norme Mnimale MN	78
3.5. Les résultats de simulations.....	80
3.5.1. Etude en simulation pour les méthodes non paramétriques	80

3.5.1.1. Méthode de Périodogramme :	80
3.5.1.2. Méthode de Spectrogramme :	93
3.5.2. Méthodes d'analyse spectrale paramétriques.....	106
3.6. Conclusion.....	114
Bibliographies	115
CHAPITRE 4 : Détection Et Classification Des Défauts.....	117
4.1. Introduction	117
4.2. Les différents approches de détection et de classification des défauts	118
4.2.1. Détection et classification simultanées	118
4.2.2. Détection et classification successives	119
4.3. Etat de l'art sur les méthodes de classification.....	119
4.3.1. Classification non-supervisée	120
4.3.1.1. L'algorithme des centres mobiles	120
4.3.2. Classification supervisée	121
4.3.2.1. Les arbres de décision	121
4.3.2.2. Les machines à support de vecteurs (SVM).....	121
4.3.2.3. Les classificateurs de Bayes	122
4.3.2.4. Les réseaux de neurones	122
4.4. Les grandes familles des réseaux de neurones.....	123
4.4.1. Les réseaux feed-forward	123
4.4.2. Les réseaux auto-organisés.....	123
4.4.3. Les réseaux récurrents.....	124
4.4.4. Les réseaux à résonance.....	124
4.5. Propriétés des réseaux de neurones artificiels.....	124
4.5.1. Apprentissage et mémoire	124
4.5.2. Sous-apprentissage, généralisation et sur-apprentissage	125
4.6. Architectures neuronales les plus utilisées en diagnostic	126
4.7. Réseau de neurones à Fonctions de Bases Radiales (RBF)	127
4.8. Extraction des paramètres de classification	133
4.8.1. Standard deviation	133
4.8.2. Kurtosis	134
4.8.3. Central moment.....	134
4.8.4. Wavelet energy	134
4.8.5. The total energy	134

4.9. Décomposition du paquet d'ondelettes.....	134
4.10. Reconnaissance et classification.....	137
4.11. Distribution des niveaux d'énergies (Multi Level Energy : ME).....	138
4.12. Les résultats de simulations.....	138
4.13. Conclusion.....	164
Bibliographies.....	166

Remerciements

Remerciements

C'est à mon Dieu que j'adresse en premier lieu mes remerciements,

Je remercie vivement le **Docteur MEHENAOUI LAMINE** de l'université de Skikda qui a accepté de juger ce travail et de présider le jury de ma thèse et pour ses encouragements sincères et ses conseils pour la finalisation de cette thèse.

Je remercie également : **Professeur LACHOURI ABDERAZEK** de l'université de Skikda, le directeur de thèse, je tiens à vous exprimer à travers ces mots ma profonde reconnaissance. Vous avez été mon enseignant, vous avez encadré mon travail d'ingénieur vous avez guidé mes pas chancelants pour le Magistère et vous avez réussi à m'apprendre, moi la novice les finesses du monde si complexe du diagnostic. Votre clairvoyance votre sagesse et votre immense savoir m'ont permis d'être dans l'universel. Veuillez trouver à travers ces lignes mon immense gratitude et mon respect sans faille.

Je remercie vivement le **Docteur KECHIDA SIHEM** de l'université de Guelma qui a accepté de juger ce travail sans hésitation. Votre avis apportera sans aucun doute les éclairages opportuns.

Un grand merci pour le **Docteur BENCOUIA NEDJEM EDDINE** et le **Docteur ZAHZOUH ZOUBIR** de l'université de Souk Ahras pour m'avoir fait l'honneur d'accepter de faire partie de ce jury avec sa joie et sa gentillesse légendaires.

Dédicaces

Dédicaces

Je dédie ce modeste travail à ma chère mère qui a sacrifié les plus belles années de sa vie pour m'avoir grandi et réussi et qui a toujours été ma source de tendresse.

A mon cher père, ma source d'espoir et mon guide du savoir, son courage et sa patience me serviront toujours d'exemples, et ses conseils éclaireront mon chemin vers l'avenir.

Je tiens à présenter mes reconnaissances et mes remerciements à ma femme Qui n'a jamais cessé de me soutenir pour que je puisse finir mes études et à qui je voudrais exprimer mes affections et mes gratitude.

Je dédie ce travail à mes enfants mehdi ayoub et Aya qui sont ma source d'inspiration et mon plus grand soutien.

*A la mémoire de mon cher frère Mehdi,
A mes frères et mes sœurs un bouquet de fleurs, et des roses pleines de belle odeur.*

*A ma Belle-mère et bon père, vers lesquelles j'ai un grand respect
A toute la famille.*

A mes amis qui je n'oublierais jamais Pour leur soutien et leur amitié.

*A la mémoire de notre cher Professeur Lakhdar Khochemane
Qu'Allah lui fasse miséricorde... Amene.*

Adlene

Résumés

Résumé

Durant ces dernières années, le diagnostic des défauts affectant les systèmes éoliens a été largement étudié. Un grand nombre des méthodes est disponible visant à améliorer la conception du système, à augmenter la qualité et la production d'énergie électrique et d'en diminuer les coûts. Malgré les résultats de la recherche, ces systèmes multi-complexes restent encore les sièges de réflexions de plusieurs laboratoires tant qu'industriels qu'académiques.

L'objectif du travail est de montrer comment la méthodologie bond graph peut contribuer efficacement à la modélisation, l'analyse et le diagnostic des systèmes de production d'énergie électrique. Ce mémoire regroupe des modèles bond graphs des principaux composants de système éolien, L'intérêt de l'utilisation de la méthodologie bond graph pour résoudre ces problèmes réside essentiellement d'une part dans l'approche énergétique unifiée de tous les domaines de la physique et dans la mise en évidence graphique de la causalité.

Ce rapport de thèse présente une nouvelle méthodologie de diagnostic de défauts au niveau d'engrenage utilisant la méthodologie Bond Graph. L'objectif est de générer des données en fonctionnement sain et en fonctionnement défaillant de ses variables. Les deux méthodes sont implémentées sous 20-sim et Matlab/ Simulink. Les données de système acquises sont traitées et analysées par la méthode **FDI**. La détection et la localisation de défauts de la machine sont obtenues par l'analyse des résidus. Les résidus sont des indicateurs de défaillance ou non du système étudié. L'analyse et la classification des résidus de modèle étudiée dans ce rapport de thèse par l'analyse spectrale de plusieurs résultats de simulation montrent l'efficacité de la méthode Choisi pour l'analyse et le diagnostic des défauts.

Mots Clé : Bond Graph, Analyse et Diagnostic, Analyse spectrale, Générateur de Résidus, Energie éolienne, Méthodes FDI, Backlash, Système mécatronique.

Abstract

In recent years, the diagnosis of faults affecting wind systems has been widely studied. A large number of methods are available to improve the design of the system, to increase the quality and production of electrical energy and to reduce the costs. Despite the results of the research, these multi-complex systems still remain the seats of reflection of several laboratories as industrial as academic. The aim of this work is to show how the bond graph methodology can contribute effectively to the modelling, analysis and diagnosis of electric power generation systems. This memory groups together the bond graph models of the main components of the wind system. The interest of using the bond graph methodology to solve these problems resides primarily on the one hand in the unified energy approach of all the domains of physics. in the graphic highlighting of causality

This thesis presents a new methodology for diagnosing gear level defects using the Bond Graph methodology. The objective is to generate data in healthy operation and in faulty operation of its variables. Both methods are implemented under 20-sim and Matlab / Simulink. The acquired system data is processed and analysed by the FDI method. Detection and localization of defects in the machine are obtained by residue analysis. The residues are indicators of failure or not of the studied system. The analysis and classification of model residues studied in this thesis report by the spectral analysis of several simulation results shows the effectiveness of the method chosen for the analysis and diagnosis of defects

Key Words: Bond Graph, Analysis and Diagnostic, Spectral Analysis, residue, wind energy, Robust, Backlash, Mechatronic

ملخص

إن التطور الحاصل في الأنظمة الخاصة بإنتاج الطاقة الهوائية أدى إلى ظهور عدة أعطال في مختلف أجزاء هذه الأنظمة، مما أدى إلى الحاجة الماسة للعديد من الطرق و التقنيات الحديثة لتحسين تشخيص هذه الأعطال لزيادة نوعية وإنتاج الطاقة الكهربائية وخفض التكاليف. وعلى الرغم من نتائج الأبحاث، لا تزال هذه الأنظمة متعددة التعقيدات مجالاً للبحث في العديد من المختبرات الصناعية والأكاديمية.

الهدف من هذا العمل هو إظهار كيف يمكن لمنهجية البوند غراف (Bond Graph) أن تساهم بشكل فعال في نمذجة وتحليل وتشخيص أنظمة توليد الطاقة الكهربائية. وتجمع هذه المذكرة نماذج منهجية البوند غراف لمختلف المكونات الرئيسية لنظام الرياح. وتكمن الفائدة من استخدام هذه المنهجية حل هذه المشاكل بواسطة خاصية الطاقة الموحدة لكل مجالات الفيزياء التي يمتاز بها من جهة و

خاصية السببية البيانية من جهة أخرى.

يقدم هذا التقرير طرح منهجية جديدة لتشخيص العيوب على مستوى المسننات باستخدام منهجية البوند غراف. والهدف من ذلك هو توليد البيانات في عملية صحيحة وفي عملية خاطئة لمتغيرات النظام. تم استخدام البرامج 20-sim و Matlab/Simulink لتوليد هذه البيانات. وتجري معالجة بيانات النظام المكتسبة وتحليلها باستخدام طريقة تحليل وعزل الأخطاء. يتم الحصول على كشف وتوطين العيوب في الجهاز عن طريق تحليل البقايا. إن تحليل وتصنيف البقايا النموذجية المدروسة في هذا التقرير تمت بواسطة طريقة التحليل الطيفي للعديد من نتائج المحاكاة لتبيين فعالية الطريقة المختارة لتحليل وتشخيص العيوب.

المفاتيح:

اكتشاف وعزل الأعطال، بوند غراف، مكاترونكس، تحليل وتشخيص الأعطال، الطاقة الهوائية، التحليل الطيفي.

Liste Des Figures

Liste des Figures

<i>Fig.1.1- Anomalies et observations classées par criticité croissante</i>	12
<i>Fig.1.2- Types des défauts</i>	12
<i>Fig.1.3- Classification des méthodes de diagnostic</i>	14
<i>Fig.1.4- Schéma fonctionnel du filtre de Kalman</i>	21
<i>Fig.1.5- Principe de l'approche par estimation des paramètres</i>	23
<i>Fig.1.6- Le principe d'un estimateur</i>	24
<i>Fig.1.7- L'architecture générale d'un tel système de surveillance</i>	27
<i>Fig.2.1- Lien Bond graph</i>	32
<i>Fig.2.2- Représentation des transferts de puissance</i>	32
<i>Fig.2.3- Représentation générale d'un élément Bond graph</i>	34
<i>Fig.2.4- Représentation générale de l'élément C</i>	35
<i>Fig.2.5- Représentation générale de l'élément I</i>	35
<i>Fig.2.6- Représentation générale des éléments Se et Sf</i>	36
<i>Fig.2.7- Représentation générale de la jonction 0</i>	36
<i>Fig.2.8- Représentation générale de la jonction 1</i>	37
<i>Fig.2.9- Transformateur TF et son équation constitutive</i>	37
<i>Fig.2.10- Gyrateur GY et son équation constitutive</i>	38
<i>Fig.2.11- Notion de causalité</i>	38
<i>Fig.2.12- Les principaux composants d'une éolienne</i>	39
<i>Fig.2.13- Modèle de l'éolienne</i>	40
<i>Fig.2.14- Profile du vent</i>	41
<i>Fig. 2.15- Coefficient de puissance pour différentes valeurs de β</i>	43
<i>Fig.2.16- Modèle de la Partie Aérodynamique sous 20-sim</i>	43
<i>Fig.2.17- Modèle mécanique de l'éolienne</i>	44
<i>Fig.2.18- Modèle à Trois masses sous le logiciel 20-sim</i>	46
<i>Fig.2.19- Backlash Mécanisme</i>	47
<i>Fig.2.20- La force élastique non linéaire</i>	47
<i>Fig.2.21- Circuit équivalent de machine asynchrone</i>	48
<i>Fig.2.22- Relation entre un système triphasé et un système diphasé équivalent</i>	49
<i>Fig.2.23- Modèle Bond Graph de la transformée de Park</i>	50
<i>Fig.2.24- Modèle de la machine asynchrone sous 20-sim</i>	50
<i>Fig. 2.25- Bond Graph système complet</i>	51
<i>Fig.2.26- Schéma synoptique du système éolien sous 20-Sim</i>	52
<i>Fig.2.27- Healthy system response</i>	54

<i>Fig.2.28- System response with $J_0=0.1$rad.....</i>	<i>55</i>
<i>Fig.2.29- System response with $J_0=0.2$ rad</i>	<i>56</i>
<i>Fig.2.30- System response with $J_0=0.4$ rad</i>	<i>57</i>
<i>Fig.2.31- Residuals generation at $J_0=0.2$ rad on Eletromagnetic torque, Low speed and hig.h speed between healthy and faulty system.....</i>	<i>58</i>
<i>Fig.2.32- Residuals generation at $J_0=0.4$ rad on Eletromagnetic torque, low speed and hig.h speed between healthy and faulty system.....</i>	<i>58</i>
<i>Fig.3.1- Principes du périodogramme et du corrélogramme</i>	<i>64</i>
<i>Fig.3.2- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétiques (C_e), (b)- Erreur sur C_e, (c)-Périodogramme(C_e) et (d)- Périodogramme(Err_{C_e}).</i>	<i>81</i>
<i>Fig.3.3- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente Ω_1, (b)-Erreur sur Ω_1, (c)- Périodogramme (Ω_1) et (d)- Périodogramme (Err_{Ω_1}).</i>	<i>82</i>
<i>Fig.3.4- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide (Ω_2), (b)-Erreur sur Ω_2, (c)-Périodogramme (Ω_2) et (d)- Périodogramme (Err_{Ω_2}).....</i>	<i>82</i>
<i>Fig.3.5- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance (C_p), (b)- Erreur sur C_p, (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_{C_p}).</i>	<i>83</i>
<i>Fig.3.6- Evolution temporelle et fréquentielle du : (a)-Couple mécanique T_m, (b)-Erreur sur T_m, (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_{T_m}).</i>	<i>83</i>
<i>Fig.3.7- Evolution temporelle et fréquentielle du : (a)-Puissance mécanique P_m, (b)-Erreur sur P_m, (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_{P_m}).</i>	<i>84</i>
<i>Fig.3.8- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétiques (C_e), (b)- Erreur sur C_e, (c)-Périodogramme(C_e) et (d)- Périodogramme(Err_{C_e}).....</i>	<i>84</i>
<i>Fig.3.9- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente (Ω_1), (b)-Erreur sur Ω_1, (c)-Périodogramme (Ω_1) et (d)- Périodogramme (Err_{Ω_1}).....</i>	<i>85</i>
<i>Fig.3.10- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide (Ω_2), (b)-Erreur sur Ω_2, (c)-Périodogramme (Ω_2) et (d)- Périodogramme (Err_{Ω_2}).....</i>	<i>85</i>
<i>Fig.3.11- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance (C_p), (b)- Erreur sur C_p, (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_{C_p})</i>	<i>86</i>
<i>Fig.3.12- Evolution temporelle et fréquentielle du : (a)-Couple mécanique T_m, (b)-Erreur sur T_m, (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_{T_m})</i>	<i>86</i>
<i>Fig.3.13- Evolution temporelle et fréquentielle du : (a)-Puissance mécanique P_m, (b)-Erreur sur P_m, (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_{P_m}).....</i>	<i>87</i>
<i>Fig.3.14- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétique C_e, (b)- Erreur sur C_e, (c)-Périodogramme (C_e) et (d)- Périodogramme (Err_{C_e}).....</i>	<i>87</i>
<i>Fig.3.15- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente Ω_1, (b)-Erreur sur Ω_1, (c)-Périodogramme (Ω_1) et (d)- Périodogramme (Err_{Ω_1}).....</i>	<i>88</i>
<i>Fig.3.16- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide Ω_2, (b)-Erreur sur Ω_2, (c)-Périodogramme (Ω_2) et (d)- Périodogramme (Err_{Ω_2}).....</i>	<i>88</i>
<i>Fig.3.17- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance C_p, (b)- Erreur sur C_p, (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_{C_p}).....</i>	<i>89</i>

<i>Fig.3.18- Evolution temporelle et fréquentielle du : (a)-Couple Mécanique T_m, (b)-Erreur sur T_m, (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_T_m).</i>	89
<i>Fig. 3.19- Evolution temporelle et fréquentielle du : (a)-Puissanc Mécanique P_m, (b)-Erreur sur P_m, (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_P_m).</i>	90
<i>Fig. 3.20- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétique C_e, (b)-Erreur sur C_e, (c)-Périodogramme (C_e) et (d)- Périodogramme (Err_C_e).</i>	90
<i>Fig.3.21- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente Ω_1, (b)-Erreur sur Ω_1, (c)-Périodogramme (Ω_1) et (d)- Périodogramme ($Err_ \Omega_1$).</i>	91
<i>Fig.3.22- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide Ω_2, (b)-Erreur sur Ω_2, (c)-Périodogramme (Ω_2) et (d)- Périodogramme ($Err_ \Omega_2$).</i>	91
<i>Fig.3.23- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance C_p, (b)-Erreur sur C_p, (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_C_p).</i>	92
<i>Fig.3.24- Evolution temporelle et fréquentielle du : (a)-Couple MécaniqueT_m, (b)-Erreur sur T_m, (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_T_m).</i>	92
<i>Fig.3.25- Evolution temporelle et fréquentielle du : (a)-Puissance Mécanique P_m, (b)-Erreur sur P_m, (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_P_m).</i>	93
<i>Fig.3.26- (a)- Evolution temporelle de C_e, (b)-Erreur sur C_e, (c)- Spectrogramme de (Err_C_e) et DSP de (Err_C_e) pour un défaut de backlash $J_0=0.1$ rad.</i>	94
<i>Fig.3.27- (a)- Evolution temporelle de Ω_1, (b)-Erreur sur Ω_1, (c)- Spectrogramme de ($Err_ \Omega_1$) et DSP de ($Err_ \Omega_1$) pour un défaut de backlash $J_0=0.1$ rad.</i>	94
<i>Fig.3.28- (a)- Evolution temporelle de Ω_2, (b)-Erreur sur Ω_2, (c)- Spectrogramme de ($Err_ \Omega_2$) et DSP de ($Err_ \Omega_2$) pour un défaut de backlash $J_0=0.1$ rad.</i>	95
<i>Fig.3.29- (a)- Evolution temporelle du C_p, (b)-Erreur sur C_p, (c)- Spectrogramme de (Err_C_p) et DSP de (Err_C_p) pour un défaut de backlash $J_0=0.1$ rad.</i>	95
<i>Fig.3.30- (a)- Evolution temporelle du T_m, (b)-Erreur sur T_m, (c)- Spectrogramme de (Err_T_m) et DSP de (Err_T_m) pour un défaut de backlash $J_0=0.1$ rad.</i>	96
<i>Fig.3.31- (a)- Evolution temporelle du P_m, (b)-Erreur sur P_m, (c)- Spectrogramme de (Err_P_m) et DSP de (Err_P_m) pour un défaut de backlash $J_0=0.1$ rad</i>	96
<i>Fig.3.32- (a)- Evolution temporelle de C_e, (b)-Erreur sur C_e, (c)- Spectrogramme de (Err_C_e) et DSP de (Err_C_e) pour un défaut de backlash $J_0=0.2$ rad.</i>	97
<i>Fig.3.33- (a)- Evolution temporelle de Ω_1, (b)-Erreur sur Ω_1, (c)- Spectrogramme de ($Err_ \Omega_1$) et DSP de ($Err_ \Omega_1$) pour un défaut de backlash $J_0=0.2$ rad.</i>	97
<i>Fig.3.34- (a)- Evolution temporelle de Ω_2, (b)-Erreur sur Ω_2, (c)- Spectrogramme de ($Err_ \Omega_2$) et DSP de ($Err_ \Omega_2$) pour un défaut de backlash $J_0=0.2$ rad.</i>	98
<i>Fig.3.35- a)- Evolution temporelle du C_p, (b)-Erreur sur C_p, (c)- Spectrogramme de (Err_C_p) et DSP de (Err_C_p) pour un défaut de backlash $J_0=0.2$ ra</i>	98
<i>Fig.3.36- (a)- Evolution temporelle du T_m, (b)-Erreur sur T_m, (c)- Spectrogramme de (Err_T_m) et DSP de (Err_T_m) pour un défaut de backlash $J_0=0.2$ rad.</i>	99
<i>Fig.3.37- (a)- Evolution temporelle du P_m, (b)-Erreur sur P_m, (c)- Spectrogramme de (Err_P_m) et DSP de (Err_P_m) pour un défaut de backlash $J_0=0.2$ rad.</i>	99

<i>Fig.3.38- (a)- Evolution temporelle de C_e, (b)-Erreur sur C_e, (c)- Spectrogramme de (Err_C_e) et DSP de (Err_C_e) pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>100</i>
<i>Fig.3.39- (a)- Evolution temporelle de Ω_1, (b)-Erreur sur Ω_1, (c)- Spectrogramme de ($Err_ \Omega_1$) et DSP de ($Err_ \Omega_1$) pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>100</i>
<i>Fig.3.40- (a)- Evolution temporelle de Ω_2, (b)-Erreur sur Ω_2, (c)- Spectrogramme de ($Err_ \Omega_2$) et DSP de ($Err_ \Omega_2$) pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>101</i>
<i>Fig.3.41- (a)- Evolution temporelle du C_p, (b)-Erreur sur C_p, (c)- Spectrogramme de ($Err_ C_p$) et DSP de ($Err_ C_p$) pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>101</i>
<i>Fig.3.42- (a)- Evolution temporelle du T_m, (b)-Erreur sur T_m, (c)- Spectrogramme de ($Err_ T_m$) et DSP de ($Err_ T_m$) pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>102</i>
<i>Fig.3.43- (a)- Evolution temporelle du P_m, (b)-Erreur sur P_m, (c)- Spectrogramme de ($Err_ P_m$) et DSP de ($Err_ P_m$) pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>102</i>
<i>Fig.3.44- (a)- Evolution temporelle de C_e, (b)-Erreur sur C_e, (c)- Spectrogramme de (Err_C_e) et DSP de (Err_C_e) pour un défaut de backlash $J_0=0.4$ rad</i>	<i>103</i>
<i>Fig.3.45- (a)- Evolution temporelle de Ω_1, (b)-Erreur sur Ω_1, (c)- Spectrogramme de ($Err_ \Omega_1$) et DSP de ($Err_ \Omega_1$) pour un défaut de backlash $J_0=0.4$ rad.....</i>	<i>103</i>
<i>Fig.3.46- (a)- Evolution temporelle de Ω_2, (b)-Erreur sur Ω_2, (c)- Spectrogramme de ($Err_ \Omega_2$) et DSP de ($Err_ \Omega_2$) pour un défaut de backlash $J_0=0.4$ rad.....</i>	<i>104</i>
<i>Fig.3.47- (a)- Evolution temporelle du C_p, (b)-Erreur sur C_p, (c)- Spectrogramme de ($Err_ C_p$) et DSP de ($Err_ C_p$) pour un défaut de backlash $J_0=0.4$ rad.....</i>	<i>104</i>
<i>Fig.3.48- (a)- Evolution temporelle du T_m, (b)-Erreur sur T_m, (c)- Spectrogramme de ($Err_ T_m$) et DSP de ($Err_ T_m$) pour un défaut de backlash $J_0=0.4$ rad.....</i>	<i>105</i>
<i>Fig.3.49- a)- Evolution temporelle du P_m, (b)-Erreur sur P_m, (c)- Spectrogramme de ($Err_ P_m$) et DSP de ($Err_ P_m$) pour un défaut de backlash $J_0=0.4$ rad.....</i>	<i>105</i>
<i>Fig.3.50- (a)- Evolution temporelle du Err_C_e, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur C_e, par la méthode de Burg, (d) FFT de Err_C_e de référence, (e) et FFT de Err_C_e estimée par Prony et la FFT de Err_C_e estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.....</i>	<i>108</i>
<i>Fig.3.51- (a)- Evolution temporelle du Err_C_e, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur C_e, par la méthode de Burg, (d) FFT de Err_C_e de référence, (e) et DSP de Err_C_e estimée par Prony et la DSP de Err_C_e estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.....</i>	<i>108</i>
<i>Fig.3.52- (a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_C_e) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_C_e) pou $J_0=0.2$ rad.....</i>	<i>109</i>
<i>Fig.3.53- (a)- Evolution temporelle du $Err_ \Omega_1$, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur Ω_1 par la méthode de Burg, (d) FFT de $Err_ \Omega_1$ de référence, (e) et FFT de $Err_ \Omega_1$ estimée par Prony et la FFT de $Err_ \Omega_1$ estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.</i>	<i>109</i>
<i>Fig.3.54- (a)- Evolution temporelle du $Err_ \Omega_1$, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur Ω_1, par la méthode de Burg, (d) FFT de $Err_ \Omega_1$ de référence, (e) et DSP de $Err_ \Omega_1$ estimée par Prony et la DSP de $Err_ \Omega_1$ estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.....</i>	<i>110</i>

<i>Fig.3.55- (a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_{Ω_1}) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_{Ω_1}) pou $J_0=0.2$ rad</i>	<i>110</i>
<i>Fig.3.56- (a)- Evolution temporelle du Err_{C_e}, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur C_e, par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et FFT de Err_{C_e} estimée par Prony et la FFT de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>111</i>
<i>Fig.3.57- (a)- Evolution temporelle du Err_{C_e}, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur C_e, par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et DSP de Err_{C_e} estimée par Prony et la DSP de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad</i>	<i>112</i>
<i>Fig.3.58- (a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_{C_e}) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_{C_e}) pou $J_0=0.3$ rad.....</i>	<i>112</i>
<i>Fig.3.59- (a)- Evolution temporelle du Err_{Ω_1}, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur Ω_1 par la méthode de Burg, (d) FFT de Err_{Ω_1} de référence, (e) et FFT de Err_{Ω_1} estimée par Prony et la FFT de Err_{Ω_1} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad.</i>	<i>113</i>
<i>Fig.3.60- (a)- Evolution temporelle du Err_{C_e}, (b)-Erreur Estimée sur C_e, par la méthode de Prony, (c)- Erreur Estimée sur C_e, par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et DSP de Err_{C_e} estimée par Prony et la DSP de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad.....</i>	<i>112</i>
<i>Fig.3.61- ((a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_{Ω_1}) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_{Ω_1}) pou $J_0=0.3$ rad.</i>	<i>114</i>
<i>Fig.4.1- Schéma bloc de la détection</i>	<i>117</i>
<i>Fig.4.2- Schéma bloc de la classification</i>	<i>118</i>
<i>Fig.4.3- Approche de détection et classification simultanées</i>	<i>118</i>
<i>Fig.4.4- Approche de détection et classification successives</i>	<i>119</i>
<i>Fig.4.5- Structure d'un réseau feed-forward</i>	<i>123</i>
<i>Fig.4.6- Modèle de Kohonen.....</i>	<i>124</i>
<i>Fig.4.7- Complexité d'apprentissage d'un réseau de neurones</i>	<i>125</i>
<i>Fig.4.8- Application des réseaux de neurones en diagnostic d'équipement industriels</i>	<i>127</i>
<i>Fig.4.9- Réseau de neurones à fonction de base radiale</i>	<i>129</i>
<i>Fig.4.10- Factorisation d'un réseau à fonction de base radiale</i>	<i>130</i>
<i>Fig.4.11- Intérêt de la factorisation de la fonction gaussienne.....</i>	<i>131</i>
<i>Fig.4.12- Avantage de la zone de couverture elliptique</i>	<i>131</i>
<i>Fig.4.13- Taux de recouvrement pour un treillis régulier unidimensionnel</i>	<i>132</i>
<i>Fig.4.14- Décomposition niveau 3 avec la transformée en ondelettes</i>	<i>136</i>
<i>Fig.4.15- Décomposition de la banque de filtres de la paquets d'ondelettes</i>	<i>137</i>
<i>Fig.4.16- Les étapes à suivre pour la classification des défauts</i>	<i>137</i>
<i>Fig.4.17- Organigramme de Traitement</i>	<i>138</i>
<i>Fig.4.18- Evolution de l'erreur du couple électromagnétique</i>	<i>139</i>
<i>Fig.4.19- Evolution de l'erreur du Ω_1</i>	<i>140</i>

<i>Fig.4.20- Evolution de l'erreur du Ω_2</i>	140
<i>Fig.4.21- Coefficients de détail Pour Ce, Omega1 dans le cas sains</i>	141
<i>Fig.4.22- Coefficients de détail Pour Omega2, Pm dans le cas sains</i>	141
<i>Fig.4.23- L'erreur sur Ce, Omega1 avec un défaut électrique sur les paramètres Rs et Ls de 5%</i>	142
<i>Fig.4.24- L'erreur sur Omega2 et Pm avec un défaut électrique sur les paramètres Rs et Ls de 5%</i>	143
<i>Fig.4.25- L'erreur sur Ce et Omega1 avec un défaut électrique sur les paramètres Rs et Ls de 5%</i>	143
<i>Fig.4.26- Coefficients de détail Pour Omega2 et Pm avec un défaut électrique Sur les paramètres Ls et Rs de 5%</i>	144
<i>Fig.4.27- L'erreur sur Ce et Omega1 avec un défaut électrique sur les paramètres Rs et Ls de 10%</i>	147
<i>Fig.4.28- L'erreur sur Omega2 et Pm avec un défaut électrique sur les paramètres Rs et Ls de 10%</i>	146
<i>Fig.4.29- Coefficients de détail Pour Ce et Omega1 avec un défaut électrique Sur les paramètres Rs et Ls de 10%</i>	146
<i>Fig.4.30- Coefficients de détail Pour Omega2 et Pm avec un défaut électrique Sur les paramètres Ls et Rs de 10%</i>	147
<i>Fig.4.31- L'erreur sur Ce et Omega1 avec un défaut électrique sur les paramètres Rs et Ls de 15%</i>	148
<i>Fig.4.32- L'erreur sur Omega2 et Pm avec un défaut électrique sur les paramètres Rs et Ls de 15%</i>	148
<i>Fig.4.33- Coefficients de détail Pour Ce et Omega1 avec un défaut électrique Sur les paramètres Ls et Rs de 15%</i>	149
<i>Fig.4.34- Coefficients de détail Pour Omega2 et Pm avec un défaut électrique Sur les paramètres Ls et Rs de 15%</i>	149
<i>Fig.4.35- L'erreur sur Ce et Omega1 avec un défaut électrique Sur les paramètres Ls et Rs de 20%</i>	150
<i>Fig.4.36- L'erreur sur Omega2 et Pm avec un défaut électrique Sur les paramètres Ls et Rs de 20%</i>	151
<i>Fig.4.37- Coefficients de détail Pour Ce et Omega1 avec un défaut électrique Sur les paramètres Ls et Rs de 20%</i>	151
<i>Fig.4.38- Coefficients de détail Pour Omega2 et Pm avec un défaut électrique Sur les paramètres Ls et Rs de 20%</i>	152
<i>Fig.4.39- L'erreur sur Ce et Omega1 avec un défaut de backlash $j_0=0.1$ rad</i>	153
<i>Fig.4.40- L'erreur sur Omega2 et Pm avec un défaut de Backlash $j_0=0.1$ rad</i>	153
<i>Fig.4.41- Coefficients de détail Pour Ce et Omega1 avec un défaut de backlash $j_0=0.1$ rad</i>	154
<i>Fig.4.42- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.1$ rad</i>	154
<i>Fig.4.43- L'erreur sur Ce et Omega1 avec un défaut de backlash $j_0=0.2$ rad</i>	156

<i>Fig.4.44- L'erreur sur Omega2 et Pm avec un défaut de Backlash $j_0=0.2$ rad</i>	<i>156</i>
<i>Fig.4.45- Coefficients de détail Pour Ce et Omega1 avec un défaut de backlash $j_0=0.2$ rad</i>	<i>157</i>
<i>Fig.4.46- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.2$ rad</i>	<i>157</i>
<i>Fig.4.47- L'erreur sur Ce et Omega1 avec un défaut de backlash $j_0=0.3$ rad</i>	<i>158</i>
<i>Fig.4.48- L'erreur sur Omega2 et Pm avec un défaut de Backlash $j_0=0.3$ rad</i>	<i>159</i>
<i>Fig.4.49- Coefficients de détail Pour Ce et Omega1 avec un défaut de backlash $j_0=0.3$ rad</i>	<i>159</i>
<i>Fig.4.50- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.3$ rad</i>	<i>160</i>
<i>Fig.4.51- L'erreur sur Ce et Omega1 avec un défaut de backlash $j_0=0.4$ rad</i>	<i>161</i>
<i>Fig.4.52- L'erreur sur Omega2 et Pm avec un défaut de Backlash $j_0=0.4$ rad</i>	<i>161</i>
<i>Fig.4.53- Coefficients de détail Pour Ce et Omega1 avec un défaut de backlash $j_0=0.4$ rad</i>	<i>162</i>
<i>Fig.4.54- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.4$ rad</i>	<i>162</i>
<i>Fig.4.55- La courbe de performance pour 10-10-10 :4</i>	<i>164</i>

Liste Des Tableaux

Liste des Tableaux

Tableau 2.1 : Signification des variables généralisées pour quelques domaines physiques	33
Tableau 2.2 : Paramètres du système utilisé dans 20-Sim	52
Tableau 2.3 : les scénarios de simulation	53
Tableau 4.1 : Mode de fonctionnement sain	142
Tableau 4.2 : Défauts sur les paramètres électriques (R_s , L_s) avec une erreur de l'ordre de 5%	144
Tableau 4.3 : Défauts sur les paramètres électriques (R_s , L_s) avec une erreur de l'ordre de 10%	147
Tableau 4.4 : Défauts sur les paramètres électriques (R_s , L_s) avec une erreur de l'ordre de 15%	150
Tableau 4.5 : Défauts sur les paramètres électriques (R_s , L_s) avec une erreur de l'ordre de 20%	152
Tableau 4.6 : Défauts de backlash d'amplitude $J_0=0.1$ rad.....	155
Tableau 4.7 : Défauts de backlash d'amplitude $J_0=0.2$ rad.....	158
Tableau 4.8 : Défauts de backlash d'amplitude $J_0=0.3$ rad.....	160
Tableau 4.9 : Défauts de backlash d'amplitude $J_0=0.4$ rad.....	163

Notations & Symboles

Symboles

V	La vitesse de l'air traversant l'aérogénérateur.
F	Force exercée sur les pales d'une éolienne à incidence variable.
ρ	Masse volumique de l'air.
R	Rayon de la surface balayée par la turbine.
E_c	L'énergie cinétique de la masse d'air qui traverse l'aérogénérateur.
C_p	Le coefficient de puissance.
C_q	Le coefficient du couple.
λ	La vitesse relative de l'éolienne.
λ_{opt}	La vitesse relative optimale de l'éolienne.
β	Angle de calage
Ω_{wt}	Vitesse de rotation de la turbine.
Ω_{mec}	Vitesse de rotation de l'arbre du générateur.
Ω_1	Vitesse de rotation de la turbine1.
Ω_2	Vitesse de rotation de la turbine2.
G	Gain du multiplicateur.
C_a	Couple aérodynamique de l'éolienne.
J_{wt}	Le moment d'inertie de la turbine.
J_{gen}	Le moment d'inertie de la MAS.
B_{wt}, B_{gen}	Les coefficients dû aux frottements visqueux de la turbine et la MAS.
T_m	Le couple mécanique sur l'arbre de la MAS.
T_h	Le couple de l'arbre Rapide.
T_l	Le couple de l'arbre lent.
Ω_{gen}	La vitesse de rotation de la MAS.
J_{wheel1}, J_{wheel2}	Les moments d'inertie des disques à engrenage.
g	Glissement.
P_{mech}	Puissance mécanique disponible au niveau de l'arbre de la machine.
d	Indice de l'axe direct.
q	Indice de l'axe en quadrature.

$[V_s]$	Vecteur tension statorique.
$[I_s]$	Vecteur courant statorique.
$[I_r]$	Vecteur courant rotorique.
$[\Phi_s]$	Vecteur flux statorique.
$[\Phi_r]$	Vecteur flux rotorique.
$[R_s]$	Matrice résistance statorique.
$[R_r]$	Matrice résistance rotorique.
$[L_s]$	Matrice inductance statorique.
$[L_r]$	Matrice inductance rotorique.
$[L_m]$:	Matrice inductance mutuelle stator-rotor.
p	Nombre de paires de pôles.
ω_s	Pulsation électrique statorique.
ω_r	Pulsation électrique rotorique.
ω	Vitesse angulaire de rotation.
$\Omega_{méc}$	Vitesse de rotation mécanique.
R_s	Résistance statorique.
R_r	Résistance rotorique.
l_s	Inductance propre d'une phase statorique.
l_r	Inductance propre d'une phase rotorique.
L_m	Inductance mutuelle entre le stator et le rotor.
V_a, V_b, V_c	Tensions simples statoriques.

Notations

FDI	Fault Detection and Isolation.
LTI	Linear Time Invariant.
LMI	Linear Matrix Inequality.
BG	Bond Graph.
RRAs	Redundancy relations Analytic.
LFT	Linear Fractional Transformations.
RBF	Radial Basis Function.
PNN	Probabilistic neural network.
FFT	Fast Fourier Transform.
WT	Wavelet Transform.
DWT	Discrete Wavelet Transform.
WPT	Wavelet Paquet Transform.

Introduction Générale

Introduction Générale

Durant ces dernières années, le diagnostic des défauts affectant les systèmes éoliens a été largement étudié. Actuellement, l'énergie éolienne est l'énergie renouvelable la plus sollicitée pour la production de l'énergie électrique, aussi bien pour des sites isolés comme appoint pour les réseaux connectés [1]. Elle peut être une alternative compétitive contribuant à la réduction de la demande de plus en plus galopante de l'électricité. Le développement et la multiplication de l'utilisation des chaînes de conversion de l'énergie éolienne ont conduit les industriels et les scientifiques à s'investir dans l'amélioration des indices technico-économiques de cette conversion et la qualité de l'énergie fournie.

La complexité croissante des systèmes de production d'énergie et les contraintes de compétitivité en termes de coût de production, disponibilité et sécurité des installations, ont mobilisé durant ces dernières années une large communauté de chercheurs pour améliorer la surveillance et le diagnostic de ce type de procédés. L'amélioration de la sûreté de fonctionnement de ces systèmes repose essentiellement sur les algorithmes de détection et d'isolation des défauts, qui consistent principalement à comparer le comportement réel du système avec des comportements de références décrivant le fonctionnement normal (pour la détection des défauts), ou décrivant différents genres de défauts (pour l'analyse et l'isolation des pannes), tout en minimisant les fausses alarmes, les non détections ainsi que les retards dans la détection des défauts.

La sûreté de fonctionnement est un enjeu majeur pour assurer une continuité et une sûreté optimale de l'outil de production. Tout changement indésirable ou un arrêt inattendu provoqueront des pertes économiques considérables. Pour éviter ce genre de problèmes, les chaînes de production doivent être dotées par des systèmes de diagnostic fiables permettant de détecter n'importe quels défauts ou changements dans l'état de fonctionnement avant la défaillance totale [2].

La détection et le diagnostic automatique des défauts sont devenus des techniques cruciales dans l'industrie en raison de l'intégration des procédures intelligentes dans les systèmes de surveillance des machines. La surveillance de défaut de backlash affectant les

engrenages dans le système éolien de production d'énergie a été l'objet de notre recherche. Les engrenages sont appelés à subir des défaillances par suite des situations d'exploitation parfois rigoureuses. L'importance de défaut de Backlash et leur influence mécanique peuvent provoquer des problèmes de fonctionnement ou de qualité de productivité [3].

Plusieurs travaux ont été réalisés dans la littérature pour développer des méthodes de diagnostic robuste en utilisant que les différentes informations disponibles pour décrire le comportement des systèmes. Deux types de méthodes sont utilisés, les méthodes qualitatives et les méthodes quantitatives. L'approche qualitative consiste à répartir l'espace paramétrique en plusieurs classes correspondant à des modes de fonctionnement connus, puis de déterminer par apprentissage les relations mathématiques entre les effets (observations des experts, mesures de capteurs et données statistiques), et les causes (les défauts). Pour les approches quantitatives, appelées aussi méthodes à base de modèles, la première étape consiste à générer des relations de redondance analytique, qui expriment la différence entre les informations issues du système réel et celles générées par son modèle de fonctionnement normal [4]. Ces relations appelées également résidus, caractérisent le mode de fonctionnement du système et sont nulles en fonctionnement normal. Cependant, la robustesse de ces approches dépend principalement de la précision du modèle. Les méthodes à base de modèles deviennent de plus en plus complexes vu la complexité des systèmes industriels et le caractère fortement non linéaire de la plupart d'entre eux.

A cet effet, nous nous sommes intéressés à développer un système de diagnostic appliqué sur un système éolien en utilisant l'outil Bond Graph (**BG**) [7]. Les outils classiques basés sur la transformée de Fourier ne permettent pas de mettre en évidence des comportements locaux non-stationnaires. Pour répondre à cette problématique, nous avons réparti ce travail de recherche selon deux étapes, ainsi la première étape concerne l'analyse temporelle et fréquentielle du comportement du système à travers des mesures effectuées sur les différentes grandeurs, en cite entre autres, le couple mécanique de la turbine, la vitesse de rotation de la turbine, la puissance mécanique de la turbine, le couple électromagnétique de la génératrice et le coefficient de puissance [8]. Une étude de comparaison entre un mode de fonctionnement sain et un mode de fonctionnement en défaut est effectuée pour générer des résidus porteurs d'information. L'évaluation de ces indicateurs a été réalisée en utilisant la distribution de l'énergie spectrale et les techniques de représentation temps-fréquence et temps-échelle ainsi que les méthodes d'analyse spectrale paramétrique [9]. La deuxième étape concerne la phase

d'identification et de classification des différents défauts du système éolien [10]. Les réseaux de neurones artificiels peuvent être exploités en diagnostic comme outil principal de classification et de surveillance. En effet, le problème de surveillance peut être considéré comme étant un problème de reconnaissance des formes et de classification où les classes correspondent aux différents modes de défaillance du système et des formes représentant le comportement du système [11].

Organisation de la Thèse :

L'objectif de ce travail est d'apporter une contribution à l'analyse et le diagnostic d'un système de conversion d'énergie éolienne à base d'une génératrice asynchrone à cage d'écureuil. Dans le but d'approfondir chacun des points mentionnés ci-dessus, la thèse est organisée en quatre chapitres.

Le premier chapitre est consacré à la présentation de l'état d'art sur les méthodes de diagnostic des défauts dans les systèmes mécatronique, Plusieurs travaux ont été réalisés dans la littérature pour développer des méthodes de diagnostic robustes, se basant sur les différentes informations disponibles pour décrire le comportement des systèmes. Deux types de méthodes sont utilisés, les méthodes qualitatives et les méthodes quantitatives.

Le second chapitre est consacré au premier lieu au notions générale de méthodologie Bond Graph et leurs différents éléments, ensuite la présentation des différentes parties de système de conversion d'énergie (la partie aérodynamique, électrique et mécanique). Un modèle mathématique de la turbine éolienne est présenté, ensuite une modélisation du défaut de backlash est présentée. A la fin du chapitre un scénario de simulation basé sur la variation du défaut de backlash est développé sous logiciel 20-sim.

Le troisième chapitre est dédié à une analyse profonde effectuée dans le domaine temporel et fréquentiel pour l'extraction des paramètres pertinents pour un éventuel diagnostic et classification. Dans cette optique, des méthodes d'analyse spectrale paramétrique et non paramétrique ou encore à haute résolution sont développées pour pouvoir discriminer l'état défectueux par rapport à un état sain. Les résultats de simulation ont prouvé l'efficacité des hypothèses prévues dans le cahier des charges. Une évaluation du **ME** (Multi-Level-Energy) est utilisée pour annoncer la présence d'un défaut en se basant sur une éventuelle comparaison par rapport à un seuil calculé durant un mode de fonctionnement normal et sain.

Le quatrième et le dernier chapitre, décrit une méthode de détection et classification basé sur les réseaux d'ondelette et l'application des réseaux de neurones pour la reconnaissance et la classification des défauts en se basant sur les coefficients de détails des ondelettes. À la fin de ce chapitre et pour vérifier notre technique de diagnostic, on a appliqué sur notre modèle.

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

Bibliographies

- [1] **F. POITIER**, *Etude et commande de génératrice asynchrone pour l'utilisation de l'énergie éolienne*, université de nante, 2003.
- [2] **S. M**, *Etude comparative des méthodes de diagnostic des machines asynchrones*, Thèse de Doctorat, Université de Biskra, 2010.
- [3] **S. E**, *Diagnostic des machines asynchrones: modèles et outils paramétriques dédiés à la simulation et à la détection de défauts*, Thèse de doctorat Ecole Centrale de Nantes, France, 1999.
- [4] **Z. M.R**, *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance*, thèse de Doctorat, Université de Franche-Comté, France, 2003.
- [5] **C. R**, *Diagnostic des défauts des machines asynchrones par reconnaissance des formes*, Thèse de doctorat, école doctorale d'électronique, d'électrotechnique et d'automatique de Lyon, 2003.
- [6] **F. Ramahaleomaiarantsoa**, *diagnostic des systemes a energies renouvelables de type eolien*, 2013.
- [7] **G. T.D**, «*Block Diagram Network Transformation*,» vol. 70, pp. 985-990, 1951.
- [8] **D. Karnopp et R. Rosenberg.**, «*System Dynamics: A Unified Approach*,» John Wiley & Sons, 1975.
- [9] **Hautier et J. Fauche**, «*Le graphe informationnel causal*,» *Bulletin de l'Union des Physiciens* , vol. 90, pp. 167-189.
- [10] **El-Bouchikhi, C. V, B. M et J. F.C**, *Etude Comparative des Techniques de Traitement du Signal Non-Stationnaires Dédiées au Diagnostic des Génératrices Asynchrones dans les Eoliennes Offshores et les Hydroliennes*, Électrotechnique du Futur, Belfort, France,, 2011.
- [11] **k. S.R et A. S.D**, «*Artificial neural network based fault identification scheme implementation for a three-phase induction motor*,» *ISA Transactions.*,, vol. Vol. 46 , n° 12, pp. 264-266, April 2007..

Chapitre I

Table des matières

1. Etat De l'Art Sur Les Méthodes De Diagnostic Des Défauts	7
1.1. Introduction	7
1.2. Dispositif se sureté de fonctionnement	7
1.3. Attributs de la sureté de fonctionnement	8
1.3.1. Disponibilité :	8
1.3.2. Fiabilité :	9
1.3.3. Efficacité :	9
1.3.4. Sécurité-innocuité (safety) :	9
1.3.5. Maintenabilité :	9
1.4. Définition liées au diagnostic	9
1.4.1. Acquisition de données :	9
1.4.2. Surveillance :	9
1.4.3. Aide à la décision :	10
1.4.4. Maintenance :	10
1.4.5. Défaut (fault) :	10
1.4.6. Défaillance (faillure) :	10
1.4.7. Panne (Break-down) :	11
1.4.8. Symptôme (Symptom) :	11
1.4.9. Résidu (Résidual) :	11
1.4.10. Diagnostic :	11
1.4.11. Perturbation :	11
1.5. Procédure de diagnostic	12
1.6. Les différents types de défauts	12
1.6.1. Les défauts actionneurs :	13
1.6.2. Les défauts capteurs :	13
1.6.3. Les défauts composants ou systèmes :	13
1.7. Méthodes de surveillance	13
1.7.1. Méthodes sans modèle mathématique	14
1.7.1.1. Les méthodes dites mono-signal	15
1.7.1.2. Les méthodes dites multi-signal	15
1.7.2. Méthodes à base de modèle	17
1.7.2.1. Méthodes de génération des résidus	19
1.7.2.1.1. Filtre de Kalman	20

1.7.2.1.2. Estimation des paramètres	22
1.7.2.1.3. Estimation d'état (observateur)	23
1.7.2.2. Redondance analytique.....	24
1.7.2.3. Approche structurelle	25
1.7.2.4. Méthode G.D.E	27
1.8. Principe de la surveillance à base de modèle	27
1.9. Conclusion.....	29
Bibliographies	30

Etat de l'art Sur Les Méthodes De Diagnostic Des Défauts

1

Ce chapitre est consacré à la présentation des outils d'analyse et de conception d'algorithmes pour la détection et l'identification des défauts (FDI) appliqués sur les systèmes éoliens. A cet effet, une procédure de diagnostic est très nécessaire dans l'industrie afin d'assurer une large fiabilité, une productivité optimale et une grande sûreté de fonctionnement des systèmes technologiques. L'apparition de défaillances sur un processus incite à la mise en œuvre des systèmes de surveillance dont l'objectif est de fournir, à tout instant, l'état du processus ou de ces organes constitutifs.

1.1. Introduction

Le diagnostic de panne est l'acte de détecter et d'isoler les défauts présents dans un système. Avec la demande croissante de sécurité et de fiabilité des systèmes industriels, motivée par des incitations économiques et environnementales, le diagnostic des défaillances est devenu de plus en plus important. Un exemple est celui des systèmes mécatronique et en particulier des éoliennes, En outre, le diagnostic précoce des pannes dans les systèmes industriels est essentiel. Un grand nombre de méthodes est disponible visant à améliorer la conception du système, à augmenter la qualité et la production et d'en diminuer les coûts.

Ce chapitre est consacré à donner un état de l'art sur les différentes méthodes et les outils de surveillance. L'intérêt s'est porté ensuite sur L'amélioration de la sûreté de fonctionnement de ces systèmes qui repose essentiellement sur les algorithmes de détection et d'isolation des défauts, pour la mise en œuvre des systèmes de surveillance dont l'objectif est de fournir, à tout instant, l'état du processus ou de ces organes constitutifs.

1.2. Dispositif de sûreté de fonctionnement

La mise en place d'une démarche de sûreté de fonctionnement présente quatre étapes [1] :

- **La première étape** : Porte sur la recherche de signatures des défaillances et s'intéresse aux phénomènes ainsi qu'aux situations critiques pouvant mettre en péril la fonction, l'environnement et la mission d'un système. Ceci amène à s'interroger sur les phénomènes pouvant conduire à une situation critique et sur les conséquences des défauts à forte probabilité d'occurrence. Cette réflexion fait partie intégrante de la démarche de sûreté de fonctionnement.

Il est donc important de bien connaître l'objet à surveiller afin d'appréhender au mieux son comportement, en l'absence et en présence de défauts. La difficulté rencontrée par le concepteur de la sûreté de fonctionnement est de savoir quels sont les éléments les plus sensibles d'une installation et à travers quelles grandeurs va-t-on être le plus à même d'observer les effets des défauts et comment vont se manifester les défauts sur ces grandeurs. Cette étape que l'on nomme par recherche de signatures des défaillances est une étape majeure dans la mise au point d'un dispositif de sûreté de fonctionnement.

- **La seconde étape** : porte sur la mise au point de méthodes de surveillance et de détection qui utilisent les résultats de la première étape. Cette partie exploite les données pour mettre au point des techniques permettant de mettre en évidence les prémices ou l'occurrence d'un défaut. Les méthodes de surveillance et de détection des défauts s'appuient généralement sur des mesures directes ou indirectes de grandeurs liées au système en fonctionnement. L'objectif de cette étape est de chercher l'apparition des signatures des défauts surveillés et de générer automatiquement des indicateurs informant de l'apparition des défauts.

- **La troisième étape** : concerne le diagnostic des défaillances. Elle consiste à analyser les données issues de la surveillance pour tenter d'identifier et de localiser la ou les causes probables de la défaillance. Dans cette étape on peut utiliser toutes les connaissances disponibles sur leur relation de cause à effet. Elle fournit des informations sur les degrés de criticité des défauts et cible les actions à prendre.

- **La quatrième étape** : est l'étape décisionnelle qui intervient pour appliquer les actions les plus appropriées afin de répondre aux exigences du cahier des charges de sûreté de fonctionnement dont le maintien de la fonction, la sécurisation et la maintenance.

1.3. Attributs de la sûreté de fonctionnement [2]

1.3.1. Disponibilité :

La disponibilité est l'aptitude d'un système à être en état d'accomplir la tâche ou la fonction pour laquelle il a été choisi, dans des conditions données et à un instant donné, c'est à dire, la capacité instantanée à rendre le service.

1.3.2. Fiabilité :

Continuité du service, ou l'aptitude d'un système à accomplir une fonction requise, dans des conditions données, pendant un intervalle de temps déterminé.

1.3.3. Efficacité :

C'est la capacité d'un système à réaliser correctement la tâche ou la fonction pour laquelle il a été choisi, lorsque les conditions de fonctionnement sont nominales.

1.3.4. Sécurité-innocuité (safety) :

Non occurrence de défaillances à caractère catastrophique.

1.3.5. Maintenabilité :

Facilité du retour à un état sans erreur après défaillance.

1.3.6. Sécurité-confidentialité (security) :

Non occurrence de défaillances causées par des fautes intentionnelles.

Ces qualités doivent être établies à l'origine de l'installation, mais aussi, être maintenues dans le temps.

1.4. Définitions liées au diagnostic**1.4.1. Acquisition de données :**

La première étape de la supervision, elle consiste à recueillir, à valider et à assurer l'acheminement des informations sur l'état du système jusqu'au poste de pilotage. Cette tâche est exécutée sans interruption et chaque instant, ces opérations impliquent l'utilisation des capteurs permettant de mesurer les différentes variables du processus. Ces informations seront utilisées dans des relations de résidus pour accomplir l'étape de détection.

1.4.2. Surveillance :

On utilise les données provenant du système pour représenter l'état de fonctionnement puis en détecter les évolutions. Elle permet également de détecter et diagnostiquer les défauts et les erreurs dans le système. En cas de dysfonctionnement, elle informe le module de

maintenance et le module de supervision. Les deux types de surveillance sont la surveillance de la commande et la surveillance du système opérant.

1.4.3. Aide à la décision :

Elle consiste à aider l'opérateur à prendre la bonne décision devant toute situation, et cela en proposant une liste d'actions qui pourrait restaurer les grandeurs optimales du système. Dans cette étape, l'opérateur est toujours maître de la situation, car le système d'aide à la décision n'agit jamais, mais informe et conseille seulement. De ce fait le système ne calcule pas une valeur précise, mais propose plutôt quel moyen d'action devrait être exécuté.

1.4.4. Maintenance :

La maintenance est l'étape qui intervient généralement après l'étape de prise de décision. Elle consiste à maintenir ou à restaurer les performances des composants d'une façon globale, pour l'accomplissement de sa tâche requise. Ces activités sont une combinaison d'activités techniques, administratives et de gestion.

1.4.5. Défaut (Fault) :

Tout écart entre la caractéristique observée sur le dispositif et la caractéristique de référence, lorsque celui-ci est en dehors des spécifications. Ou n'importe quel état indésirable d'un composant ou d'un système. Un défaut n'implique pas nécessairement une défaillance. La notion de défaut inclut celle de défaillance ; un défaut n'altère pas nécessairement le fonctionnement d'un système physique mais peut présager d'une défaillance à venir [3].

1.4.6. Défaillance (Failure) :

Une défaillance définit une anomalie fonctionnelle au sein d'un système physique, c'est-à-dire caractérise son incapacité à accomplir certaines fonctions qui lui sont assignées. Les défauts incluent les défaillances mais la réciproque n'est pas vraie. Un système peut remplir sa fonction tout en présentant une anomalie de comportement. Par exemple, une machine électrotechnique peut produire un bruit anormal tout en entraînant correctement une charge, en supposant que telle soit sa fonction. Le bruit anormal est un défaut qui peut permettre de présager d'une défaillance à venir. La recherche de défauts est donc fondamentale en diagnostic [3]. Perte partielle ou totale des fonctionnalités du système qui le rend incapable de délivrer le service pour lequel il a été conçu.

1.4.7. Panne (Break-down) :

La panne est l'inaptitude d'un dispositif à accomplir la fonction vitale. Il est clair que dès l'apparition d'une défaillance, caractérisée par la cessation du dispositif à accomplir sa fonction, on déclarera le dispositif en panne.

1.4.8. Symptôme (Symptom) :

Caractère distinctif d'un état fonctionnel anormal.

1.4.9. Résidu (Résiduel) :

Souvent, lorsque le modèle comportemental de référence est analytique, les signaux porteurs de signes ou de symptômes sont appelés résidus parce qu'ils résultent d'une comparaison entre un comportement réel et un comportement de référence.

1.4.10. Diagnostic :

Un diagnostic est un état expliqué d'un système physique compatible avec les informations disponibles sur le comportement réel du système et avec le modèle de comportement de référence disponible. Habituellement, le diagnostic est exprimé par les états des composants ou les états des relations de description du comportement [4].

1.4.11. Perturbation :

Entrée du système physique qui n'est pas une commande. Autrement dit, c'est une entrée non contrôlée. La figure (**Fig.1.1**) représente les anomalies suivant leur criticité. Il existe également une criticité croissante entre défaillance et panne. De la non-conformité (ou anomalie) dans le cas d'une défaillance, on passe à une inaptitude à accomplir une fonction dans le cas d'une panne. Perte partielle ou totale des fonctionnalités du système qui le rend incapable de délivrer le service pour lequel il a été conçu [4].

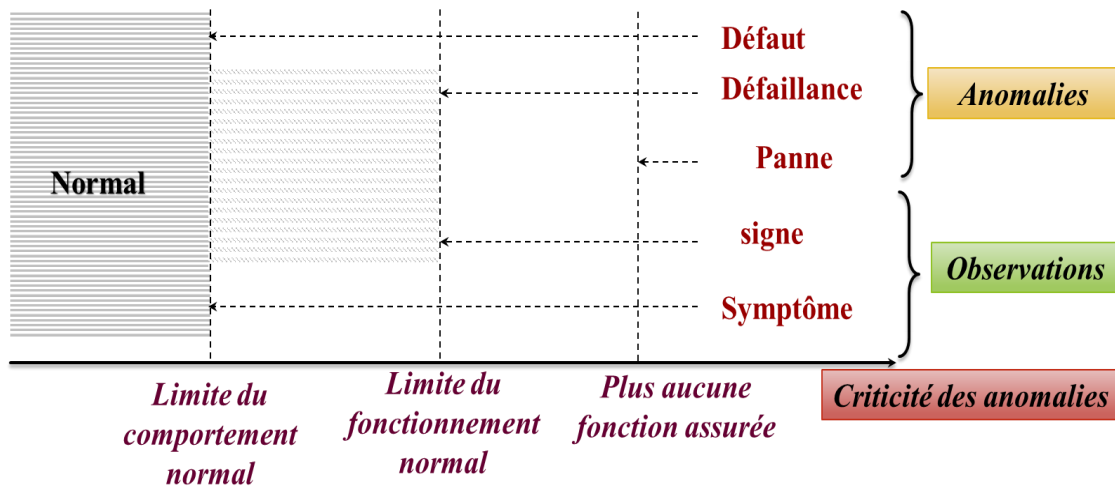


Fig.1.1- Anomalies et observations classées par criticité croissante.

1.5. Procédure de diagnostic

Dans la procédure de diagnostic, on distingue deux étapes principales : la détection et la localisation des défauts et en plus l'identification dans certaines méthodes. Les deux mots suivants « résidu » et « symptômes » sont généralement rattachés aux trois mots précédents. En pratique, dans un équipement industriel, lorsqu'un défaut apparaît le système de diagnostic détecte l'anomalie puis, identifie-la (ou les) cause(s) pour qu'il puisse être isolé.

1.6. Les différents types de défauts

Un défaut est défini comme étant un écart non permis entre la valeur réelle d'une caractéristique du système et sa valeur nominale. Comme le montre la figure (Fig.1.2), les défauts sont des événements qui apparaissent à différents endroits du système. En fonction de leur localisation, trois types de défauts sont distingués : défauts actionneurs, défauts capteurs et défauts systèmes (ou défauts composants).

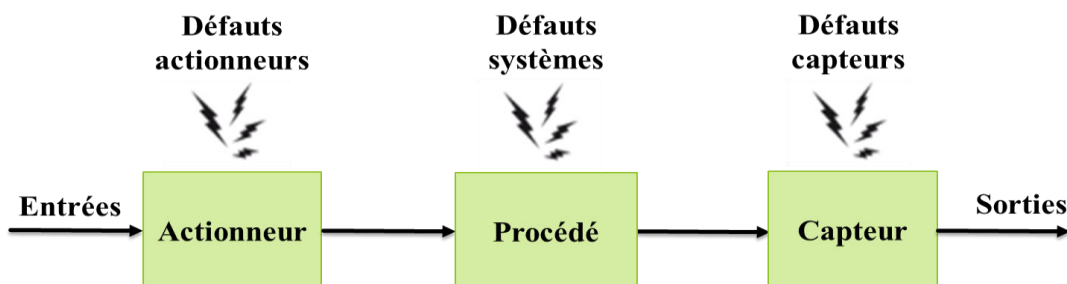


Fig.1.2- Types des défauts.

1.6.1. Les défauts actionneurs :

Les défauts actionneurs agissent au niveau de la partie opérative et détériorent le signal d'entrée du système. Ils représentent une perte totale (défaillance) ou partielle d'un actionneur agissant sur le système. Un exemple de perte totale d'un actionneur est un actionneur qui est resté "collé" sur une position entraînant une incapacité à commander le système par le biais de cet actionneur. Les défauts actionneurs partiels sont des actionneurs réagissant de manière similaire au régime nominal mais en partie seulement, c'est-à-dire avec une certaine dégradation dans leur action sur le système. (Perte de puissance d'un moteur, fuite dans un vérin, ..., etc.).

1.6.2. Les défauts capteurs :

Ce type de défaut est la cause d'une mauvaise image de l'état physique du système. Un défaut capteur partiel produit un signal avec plus ou moins d'adéquation avec la valeur vraie de la variable à mesurer. Ceci peut se traduire par une réduction de la valeur affichée par rapport à la valeur vraie, ou de la présence d'un biais ou de bruit accru empêchant une bonne lecture. Un défaut capteur total produit une valeur qui n'est pas en rapport avec la grandeur à mesurer ($0, \infty$).

1.6.3. Les défauts composants ou systèmes :

Ce type de défaut provient du système lui-même ; bien souvent les défauts n'appartenant pas à un défaut capteur ou actionneur sont classés de manière arbitraire dans cette catégorie. Néanmoins, un défaut composant résulte de la casse ou de l'altération d'un composant du système réduisant les capacités de celui-ci à effectuer une tâche. En pratique, ceci revient à considérer une modification des caractéristiques du système proprement dit (la CTN : résistance à Coefficient de Température Négatif, d'une chaufferie est cassée, un roulement est altéré, ..., etc.).

1.7. Méthodes de surveillance

Les méthodes de diagnostic se distinguent selon différents critères: la dynamique de procédé (discret, continu ou hybride), sa complexité, l'implémentation de diagnostic en ligne et/ou hors ligne, la nature d'information (qualitative et/ou quantitative), sa profondeur (structurelle, fonctionnelle et/ou temporelle), et sa distribution (centralisée, décentralisée ou

distribuée)...

Dans ce contexte, plusieurs classifications sont proposées dans la littérature [5] [6] [7]. Ces classifications sont influencées par les terminologies et les contextes particuliers de chaque communauté et ne sont pas toujours homogènes.

L'objectif est de déterminer la méthode la plus appropriée pour la résolution de notre problème de détection et diagnostic, ainsi que, positionner la classe des méthodes de diagnostic qui nous intéresse parmi les différentes méthodes de la littérature. Nous proposons une classification non exhaustive des méthodes de diagnostic en deux grandes familles (**Fig.1.3**) :

- Les méthodes sans modèle mathématique qui ne nécessitent pas de connaissances du système physique, mais utilisent des connaissances superficielles ;
- Les méthodes à base de modèles qui nécessitent une connaissance approfondie du système physique.

1.7.1. Méthodes sans modèle mathématique

Pour certaines applications industrielles, la conception d'un modèle mathématique est difficile, voire impossible à obtenir, à cause des nombreuses reconfigurations intervenant dans le processus de production ou de la complexité des phénomènes mises en jeu. Dans ce cas, on a recours à des méthodes qui ne nécessitent aucune connaissance approfondie du procédé [8]. Deux classes, dans ce type d'approches, peuvent se présenter :

- Les méthodes quantitatives ou appelées méthodes à base de connaissances ;
- Les méthodes qualitatives ou méthodes basées sur le traitement de données.

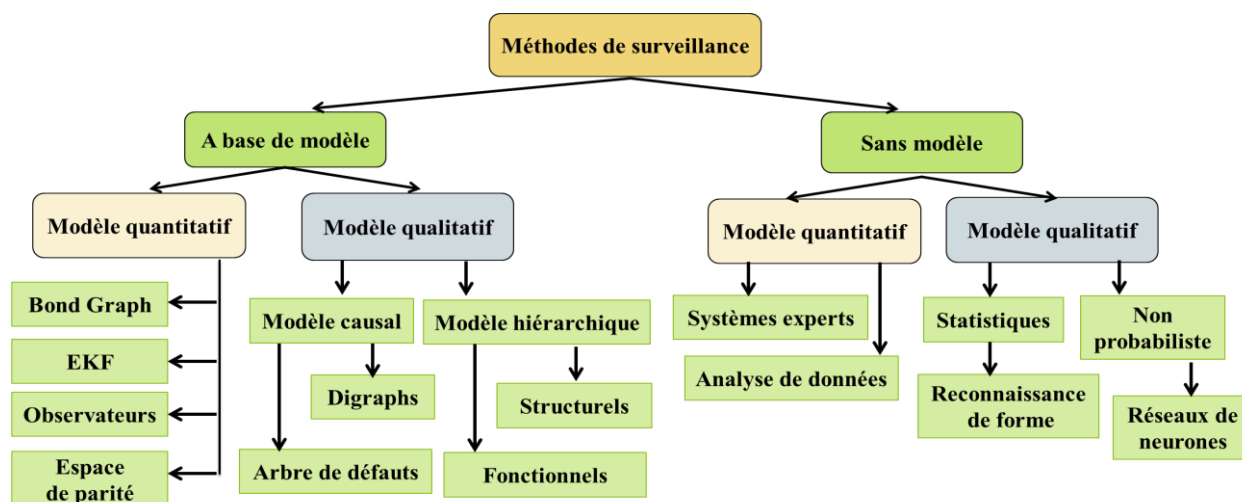


Fig.1.3- Classification des méthodes de diagnostic.

Comme présenter dans [9] les méthodes de diagnostic sans modèle mathématique sont :

1.7.1.1. Les méthodes dites mono-signal

a. Vérification des seuils atteints

Les mesures sont comparées à des seuils critiques définis par avance. Le fait de dépasser cette limite présente des dangers quant à l'utilisation du processus ; le système est mis en défaut. Dans beaucoup de systèmes, deux niveaux limites sont définis : les services du premier niveau conduisent seulement à l'avertissement préalable de l'existence d'un défaut, tandis que le deuxième niveau déclenche des mesures d'urgence.

b. Mise en place des capteurs dédiés

Ces capteurs peuvent être soit des détecteurs vérifiant de manière simple si les valeurs critiques sont atteintes ou non (par exemple : température limite ou pression) ou soit des capteurs mesurant des variables spécifiques (par exemple : bruit, vibration et élongation).

c. Le traitement statistique

Le traitement statistique du signal consiste à calculer les paramètres statistiques de certaines variables significatives du processus tels que les moments statistiques (moyenne, variance, ..., etc.), la somme cumulée, ..., etc. Chacune des valeurs statistiques est testée afin de détecter un défaut présent sur le signal.

d. L'analyse spectrale

Certaines mesures ont un spectre typique de fréquence sous des conditions normales de fonctionnement ; toute déviation de celui-ci est une indication d'anomalie. Certains types de défaut peuvent même avoir une signature caractéristique dans le spectre qui peut être utilisé pour l'isolation des défauts.

1.7.1.2. Les méthodes dites multi-signal

a. La redondance matérielle

La redondance matérielle consiste à la mise en place d'une série de capteurs mesurant la même grandeur physique sur un même organe du système. Les comparaisons par différence des mesures des capteurs deux à deux forment alors les résidus. Si un des capteurs est défaillant, il

est alors détecté et isolé facilement, car il affecte tous les résidus où il intervient. De nombreuses applications industrielles appliquent cette méthode de diagnostic. Cette méthode est principalement dédiée à des systèmes présentant des hauts risques, tels les centrales nucléaires, l'aéronautique, ..., etc. Il s'agit des systèmes sur lesquels la sécurité prime sur le coût et la maintenance des capteurs.

b. Les systèmes experts

L'approche par systèmes experts est différente des méthodes précédentes, dans le sens où elle vise à évaluer les symptômes obtenus par la détection matérielle ou logicielle. Le système expert se compose habituellement d'une combinaison des règles logiques du genre :

SI [état du système i] **ET** (fait observable)

ALORS [état du système j],

Où chaque conclusion peut, alternativement, servir d'état dans une prochaine règle jusqu'à ce que la conclusion finale soit atteinte. Le système expert peut soit fonctionner grâce à l'information qui lui est présentée par la détection matérielle ou logicielle ou soit interagir avec un opérateur humain, s'enquérant auprès de lui des symptômes particuliers et le guidant au travers des processus entièrement logiques [10].

c. Méthodes qualitatives

Les méthodes qualitatives ont pour cadre l'approche logique provenant de la communauté Intelligence Artificielle. Ces méthodes reposent sur la quantification des signaux d'entrées et de sorties. Dès lors, tous les signaux sont partitionnés en valeurs discrètes tout en s'assurant que le modèle fournit les informations nécessaires afin de distinguer le cas sans défaut du cas avec défaut. L'identification du modèle qualitatif peut être faite grâce à un automate où chaque région est représentée par un mode. Le passage d'un mode à l'autre se fait par le franchissement de valeurs frontières et cela avec une probabilité donnée. Le diagnostic consiste à regarder la concordance entre les régions des sorties vis-à-vis des régions des entrées et cela pour un certain nombre de défauts définis.

d. L'analyse en composantes principales – ACP

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'un quelconque modèle. Le but de l'ACP est d'identifier la structure de dépendance entre des observations multi-variables afin d'obtenir une description ou une représentation compacte de ces dernières. L'analyse en composante principale peut être vue comme une technique de projection orthogonale linéaire qui projette les observations multidimensionnelles représentées dans un espace de dimension m (m est le nombre de variables observées) dans un sous-espace de dimension inférieure $l < m$ en maximisant la variance des projections. Le calcul de distances par rapport à ces axes sert d'outil de détection de valeurs aberrantes. Dans ce sens, l'ACP peut être considérée comme une technique de minimisation de l'erreur quadratique d'estimation ou une technique de maximisation de la variance des projections (il faut noter que ces deux critères sont équivalents).

1.7.2. Méthodes à base de modèle

Les méthodes de diagnostic à base de modèle sont principalement dérivées des techniques utilisées par les automaticiens et impliquent une connaissance approfondie du fonctionnement sous la forme de modèles mathématiques explicites du processus qui devront être obligatoirement valides expérimentalement avant toute utilisation pour le diagnostic.

Les systèmes traités dans ce mémoire sont des systèmes dynamiques caractérisés par une opération à temps continu. Leur description mathématique peut être sous la forme d'équations différentielles ou des représentations équivalentes par transformation (Laplace).

La plupart des méthodes à base de modèle repose sur le concept de **redondance analytique**. [11], [12], [13]. Les relations de redondance analytique sont des équations déduites du modèle analytique, qui admettent pour entrées uniquement les variables mesurées. L'idée peut être étendue à la comparaison de deux quantités idéalement égales et générées analytiquement, obtenues à partir de différents ensembles de variables. Dans chacun des cas, leurs différences, appelées **résidus**, indiquent la présence de défauts sur le système.

La génération de résidus doit être suivie de **l'évaluation de résidus**, afin de parvenir aux décisions de détection et de localisation. A cause de la présence de bruit et d'erreurs de modélisation, les résidus ne sont jamais nuls, même en fonctionnement normal. Ainsi, la prise

de décision nécessite la comparaison des résidus a certains seuils obtenus de manière empirique ou théorique.

Pour faciliter la localisation du défaut, les générateurs de résidus sont généralement conçus pour produire des *résidus de localisation*, comportant des propriétés structurelles et directionnelles. Les décisions de localisation peuvent alors être obtenues dans un cadre structurel (booléen) ou directionnel (géométrique), avec ou sans utilisation d'outils statistiques.

Une approche réaliste de diagnostic à base de modèle explicite suppose la connaissance de la nature des défauts réels pouvant affecter le système ainsi que leurs descriptions en termes de symptômes. Un défaut sur un système peut être d'origine diverse. Il peut provenir par exemple de :

- Conception et/ou assemblage incorrect ;
- Fonctionnement incorrect ;
- Manque d'entretien ;
- Vieillesse ou usure en fonctionnement normal.

Leur apparition peut être brusque avec une grande ampleur ou graduelle. Un aspect important d'un système de diagnostic à base de modèle est la nature du défaut que l'on cherche à détecter. On peut distinguer les défauts dits **additifs** de ceux dits **multiplicatifs**.

Dans le cadre du diagnostic à base de modèle, on adopte les conventions suivantes :

- On suppose que les défauts ne sont pas initialement présents sur le système mais apparaissent plus tard. Les défauts sont généralement décrits par des fonctions temporelles déterministes et inconnues. Par exemple, un défaut saut et un défaut dérive peuvent être modélisés respectivement à l'aide d'une fonction échelon et d'une fonction rampe dont l'instant d'occurrence et l'ampleur (magnitude) sont inconnus.
- On peut aussi parler de perturbations additives, qui sont des entrées déterministes et inconnues au système. La différence entre perturbation additive et défaut additif est subjective : une perturbation est une nuisance qu'on désire ignorer alors qu'un défaut est une entrée inconnue occasionnant des divergences de comportement entre le modèle et le système et qu'on cherche à détecter et localiser.
- Tout bruit provenant du système, de l'actionneur ou du capteur est considéré comme signal aléatoire centre (toute moyenne non nulle est gérée comme défaut ou perturbation).

- Les erreurs de modélisation sont les écarts entre le modèle (paramètres du modèle) et le système réel. Elles peuvent être présentes depuis les origines du système et/ou peuvent apparaître lors des changements de point de fonctionnement et/ou simplement au cours du temps. Elles sont des nuisances qu'on cherche à supprimer. Elles peuvent être considérées comme perturbations multiplicatives, à l'opposé des défauts multiplicatifs qui sont aussi des écarts entre le modèle et le vrai système, mais qu'on désire détecter.

Comme mentionné précédemment, les résidus générés pour détecter les défauts peuvent aussi réagir en présence du bruit, de perturbations ou d'erreurs de modélisation. Rendre les résidus insensibles à ces différentes sources est l'un des aspects les plus importants dans la conception d'algorithme de détection et de diagnostic. En particulier :

- Pour traiter les effets du **bruit**, les résidus doivent être d'abord filtrés avant d'être évalués au moyen de techniques statistiques. L'évaluation peut toutefois être entravée par le manque d'informations suffisantes sur les propriétés statistiques du bruit et la manière dont le système réagit au bruit. Ceci est particulièrement le cas en boucle fermée ;
- **Le découplage de perturbation** peut être pris en compte dans la conception du générateur de résidus. Cependant ceci peut aller à l'encontre de la performance de localisation avec le degré de liberté qu'on dispose pour la conception ;
- **La robustesse par rapport aux erreurs de modélisation** est le problème fondamental en diagnostic à base de modèle. Il existe plusieurs méthodes qui reposent généralement sur des techniques d'optimisation. Malheureusement, ce problème n'admet pas de solution facile et les techniques de résolution connues ne sont efficaces que dans des circonstances limitées.

1.7.2.1. Méthodes de génération des résidus

Comme mentionné plus haut, avant toute mise en application d'une méthode de diagnostic à base de modèle, on doit d'abord disposer d'une représentation Mathématique du système qui permettra de générer des signaux résidus, indicateurs de défauts. Les méthodes de génération de résidus robustes peuvent être classées en quatre grandes familles qui sont plus ou moins équivalentes.

1.7.2.1.1. Filtre de Kalman

En 1960, Kalman publia son fameux article décrivant une solution récursive du problème de filtrage linéaire des mesures discrètes. Depuis ce temps, le filtre de Kalman a fait l'objet de nombreuses recherches et applications.

Le filtre de Kalman traite le problème d'estimation d'état $x \in R^n$ d'un système gouverné par les équations suivantes :

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) + w(t) \\ y(t) &= Cx(t) + Du(t) + v(t) \end{aligned} \quad (1.1)$$

Les signaux w et v sont des bruits blancs gaussiens centres et supposés indépendants. L'équation du filtre de Kalman est donnée par :

$$\begin{aligned} \dot{\tilde{x}} &= (A\tilde{x} + Bu) + F_k(y - \tilde{y}) \\ \tilde{y} &= C\tilde{x} - Du \end{aligned} \quad (1.2)$$

Dans l'équation (1.2), le modèle du système est exploité pour prédire l'évolution de l'état du système à partir de l'estimation courante \tilde{x} . Cette prédiction est recalée en fonction de l'erreur $e = y - \tilde{y}$ grâce au gain du filtre K_f . Afin d'obtenir un estimateur asymptotiquement non biaisé (l'Espérance mathématique de l'erreur d'estimation tendant vers 0 à l'infini), le gain K_f doit être choisit telle que la matrice $A - F_k C$ soit stable. En effet soit $\varepsilon = x - \tilde{x}$ l'erreur d'estimation associée au filtre (1.3), on a :

$$\dot{\varepsilon} = (A - F_k C)\varepsilon + w - F_k v \quad (1.3)$$

Les bruits w et v étant gaussiens d'Espérance mathématique nulle, alors, à l'infini, l'erreur e est aussi gaussienne d'Espérance mathématique nulle si et seulement si la matrice $A - F_k C$ est stable. Le schéma correspondant est représenté sur la figure (**Fig.1.4**).

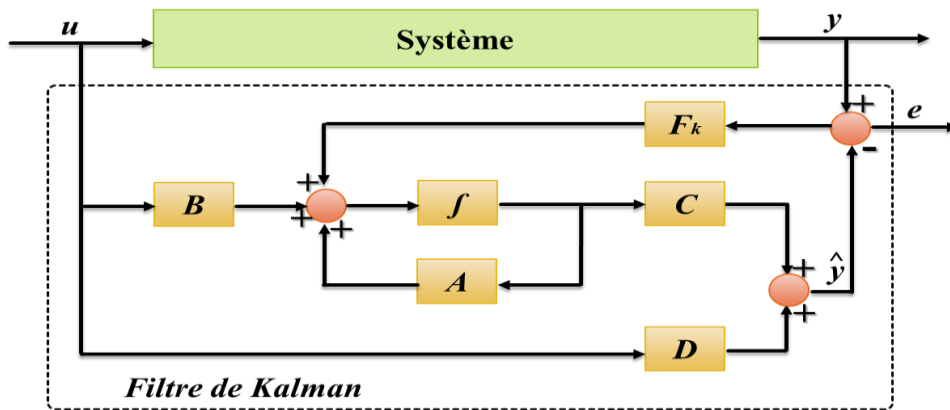


Fig.1.4- Schéma fonctionnel du filtre de Kalman.

L'erreur de prédiction e du filtre de Kalman peut être utilisée comme résidu de détection de défaut ; sa moyenne est nulle en l'absence de défauts (et perturbations) et devient non nulle dans le cas contraire. Puisque la suite d'erreur est supposée blanche, les tests statistiques sont relativement faciles à construire.

Une méthode bien connue utilisant le filtre de Kalman est l'estimation à base de modèles multiples adaptative ou le système est représenté par un modèle stochastique linéaire avec des incertitudes paramétriques (qui représentent les défauts) dans la matrice d'état.

La localisation de défaut est plus difficile avec le Filtre de Kalman ; il est nécessaire de construire un banc de filtres de détection, dédié à chaque défaut suspecté, et de vérifier la cohérence des filtres avec les observations réelles, ce qui pourrait entraîner des coûts élevés de calcul.

Le modèle analytique le plus utilisé exprime le comportement d'un système par un ensemble d'équations linéaires :

- **Modèle du système :**

$$\begin{cases} x(t + 1) = A(\theta_p)x(t) + B(\theta_p)u(t) \\ x(t_0) = x_0 \end{cases} \quad (1.4)$$

Avec :

$x(t) \in R^n$ Vecteur d'état du système à l'instant t

$u(t) \in Rp$	Vecteur de commande à l'instant t
$\theta p \in Rq$	Vecteur des paramètres
$A(\theta p)$ et $B(\theta p)$	Sont des matrices de dimensions convenables
$t, t + 1$	Sont les instants d'échantillonnage

- Modèle de la mesure :

$$y(t) = C(\theta_s)x(t) \quad (1.5)$$

Avec :

$y(t) \in Rm$	Vecteur des sorties.
θ_s	Vecteur des paramètres de mesure.
$C(\theta_s)$	Matrice de mesure.

Rappelons que les résidus sont des variables dont la valeur est égale à zéro en cas de fonctionnement idéal. La vérification en temps réel de la valeur des résidus oblige la réception à tout instant t des valeurs de commande et de sortie, respectivement $[u(t), u(t - 1), \dots]$ et $[y(t), y(t - 1), \dots]$. Pour la construction de tels résidus, trois façons de procéder sont principalement utilisées : l'estimation des paramètres, l'estimation d'état et la redondance analytique.

1.7.2.1.2. Estimation des paramètres

A partir des signaux d'entrées/sorties, les paramètres θ_p et θ_s sont estimés en utilisant des procédures d'identification. Les résidus sont ensuite générés simplement en comparant les valeurs estimées avec les valeurs nominales (supposées connues). Le vecteur des résidus est alors :

$$r(t) = \begin{bmatrix} \theta_{pN} \\ \theta_{sN} \end{bmatrix} - \begin{bmatrix} \hat{\theta}_{pN} \\ \hat{\theta}_{sN} \end{bmatrix} \quad (1.6)$$

Où :

$\theta_p(t)$ et $\theta_s(t)$ sont les paramètres des systèmes et des capteurs, estimés à l'instant t , et θ_{sN} θ_{pN} sont leurs valeurs nominales.

Lorsque les valeurs nominales ne sont pas connues, il suffit de les remplacer par des valeurs estimées à l'instant $(t - 1)$.

$$r(t) = \begin{bmatrix} \hat{\theta}_p(t-1) \\ \hat{\theta}_s(t-1) \end{bmatrix} - \begin{bmatrix} \hat{\theta}_p(t) \\ \hat{\theta}_s(t) \end{bmatrix} \quad (1.7)$$

Dans ce cas, l'écart des résidus par rapport à zéro est le résultat des variations des paramètres.

La connaissance sous-jacente du système exprime simplement que dans des conditions opératoires normales, les paramètres du système demeurent constants. Un schéma de principe de cette méthode est donné par la figure (Fig.1.5).

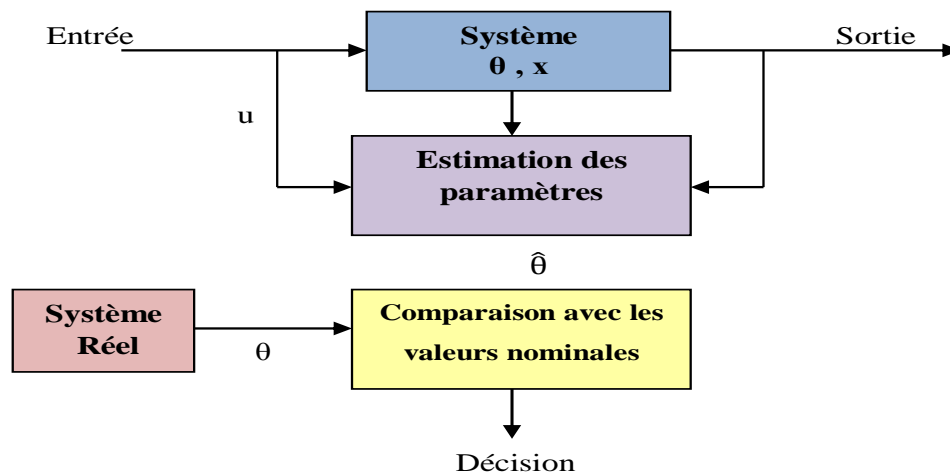


Fig.1.5- Principe de l'approche par estimation des paramètres.

1.7.2.1.3. Estimation d'état (observateur)

Remarque : Dans cette approche, une alarme est associée à chaque résidu, c'est à dire à chaque paramètre surveillé du système. Son déclenchement est démonstratif d'un écart anormal entre la valeur nominale du paramètre et sa valeur réelle (telle qu'elle est estimée par l'algorithme d'identification). Les déviations des paramètres sont en général indépendantes, cette approche limite donc les avalanches d'alarmes (lorsque les modèles utilisés ne sont pas grossièrement faux).

Une approche semblable à l'estimation des paramètres est l'estimation de l'état. En utilisant les signaux d'entrées et de sorties, l'état du système $x(t)$ et ses sorties $y(t)$ sont estimés (les sorties peuvent être estimées directement sans passer par l'estimation préalable de l'état).

Les résidus sont générés par comparaison des sorties réelles et de leurs estimations. Le vecteur des résidus s'exprime sous la forme :

$$r(t) = y(t) - \hat{y}(t) \quad (1.8)$$

Où $\hat{y}(t)$ est l'estimation de la sortie à l'instant t . Le principe général d'un estimateur de sortie est donné par la figure (Fig.1.6). Des travaux de diagnostic fondés sur les observateurs ont été développés [14].

Remarque :

Cette approche associe un résidu à chaque capteur du système. Chaque alarme générée est significative de la défaillance du capteur correspondant. Ces défaillances n'étant en général pas corrélatées, les risques d'avalanche d'alarmes sont réduits. Les difficultés résident dans la construction de l'observateur surtout pour les systèmes en génie des procédés où la mise sous forme d'état des modèles n'est pas triviale.

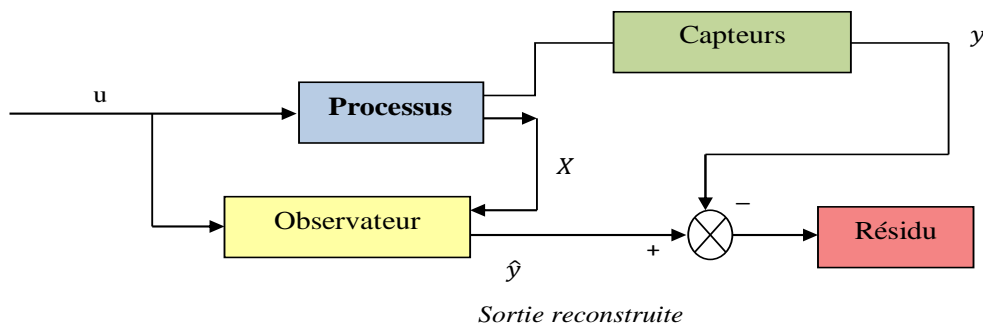


Fig.1.6- Le principe d'un estimateur.

1.7.2.2. Redondance analytique

Cette approche conduit à une réécriture des équations d'état et de mesure, dans lesquelles les variables connues (commandes et sorties) sont autorisées à figurer. Dans le cas linéaire, ces équations sont appelées équations de parités, et relations de redondance analytique (RRA) dans le cas le plus général.

Une relation de redondance analytique représente une propriété d'invariance du système non défaillant sous la forme :

$$\phi[u(t, t - p), y(t, t - p)] = 0 \quad (1.9)$$

Cependant, cette égalité ne sera jamais vérifiée, le système n'étant jamais dans des conditions de fonctionnement idéal. Dans ce sens, le vecteur des résidus construit à partir des relations de redondance analytique aura la forme :

$$r(t) = \phi[u(t, t - p), y(t, t - p)] \quad (1.10)$$

De nombreux schémas de calcul ont été spécifiquement construits pour chacune de ces trois approches (identification des paramètres des systèmes en temps continu, filtres de Kalman, observateurs et résidus structurés). Un certain nombre de propriétés d'équivalence ont été prouvées [15], et de nombreuses applications ont été développées pour la surveillance de systèmes technologiques.

Remarque :

A chaque relation entrée/sortie du système, cette approche associe un résidu. Les corrélations entre les réactions des différents résidus sont traitées à l'aide de la table des signatures binaires des défaillances. Les défaillances capteurs, actionneurs et paramètres n'engendrent pas d'avalanche d'alarmes. On parle de défaillances indépendantes.

1.7.2.3. Approche structurelle

Pour les systèmes de grande taille, l'application des approches qui viennent d'être présenté n'est pas triviale. En effet, ces méthodes dépendent de la disponibilité des modèles analytiques de bonne qualité décrivant d'une part le système et ses actionneurs, d'autre part le système de mesure.

Pour la génération des résidus, ces méthodes nécessitent la connaissance des valeurs numériques des paramètres. L'approche structurelle utilise une connaissance très pauvre du système.

Elle s'avère de ce fait très intéressante lorsqu'on se situe dans les premières phases du processus de conception du système de surveillance, ou lorsqu'il s'agit de concevoir des extensions d'un système existant. Dans le domaine de la surveillance, les concepts structurels n'ont été utilisés jusqu'à peu que pour mettre en place les procédures de localisation qui constituent la troisième phase pour tout système de surveillance. Ils constituent en fait un cadre général pour la conception des systèmes de surveillance, permettant de générer, de calculer, d'évaluer et d'implémenter une procédure de surveillance utilisant les relations de redondance analytique.

L'analyse structurelle est l'analyse des propriétés structurelles du système, c'est-à-dire des propriétés qui sont indépendantes des valeurs réelles des paramètres (plus exactement, des propriétés qui sont vraies presque partout dans l'espace des paramètres). L'analyse structurelle s'applique aux modèles linéaires comme aux modèles non linéaires, elle n'exige aucune précision du modèle de calcul du comportement et permet une représentation homogène de tous les types de modèles par la matrice d'incidence d'un graphe biparti [15].

Enfin, l'analyse structurelle traite uniquement les données binaires et s'avère efficace pour l'analyse de grands systèmes (complexes). Bien que les données d'entrée soient extrêmement pauvres, elles constituent la plus grande partie de connaissance nécessaire à la conception des systèmes de surveillance. En effet, à l'aide de l'analyse structurelle, plusieurs étapes du processus de conception sont franchies, on cite :

- a) L'analyse des redondances locales du système, permettant de mettre en évidence les possibilités de surveillance ;
- b) Le problème de placement des capteurs ;
- c) La détermination des séquences de calcul dont le résultat est un résidu (graphe orienté) ;
- d) L'analyse de la structure des résidus dont le but d'évaluer la détectabilité et la solvabilité des défaillances ;
- e) L'analyse de la structure des résidus pour l'implémentation distribuée des algorithmes de surveillance ;
- f) L'utilisation des propriétés structurelles et causales des modèles band graph permet de générer les **RRA** formelles [16].

1.7.2.4. Méthode G.D.E

Il existe aussi une méthode nommée **G.D.E (General Diagnosis Engine)** [17]. Cette méthode se divise en quatre grandes parties. La première étape consiste à faire le calcul des grandeurs du système à partir des modèles des composants et des observations. La deuxième étape a pour but de comparer les valeurs prédites entre elles et avec les observations. Les conflits sont détectés dans le cas où une incohérence entre ces valeurs est détectée. Dans la troisième étape, il s'agit de construire une liste de candidats possibles (les composants dont les pannes peuvent expliquer le comportement anormal du système). Et à la quatrième étape, il s'agit de déterminer la grandeur dont l'observation est susceptible de permettre l'affinement du diagnostic.

1.8. Principe de la surveillance à base de modèles

La plupart des méthodes de surveillance se décomposent en deux étapes : la génération et l'évaluation des résidus de détection. Lors de la première étape, les signaux d'entrée et de sortie du processus sont utilisés pour générer un résidu, c'est-à-dire un signal mettant en évidence la présence d'un défaut. En général, en régime de fonctionnement normal, ce signal est statiquement nul et s'écarte notablement de zéro en présence de défauts. La structure du générateur de résidus est cependant liée à la méthode de surveillance utilisée [18].

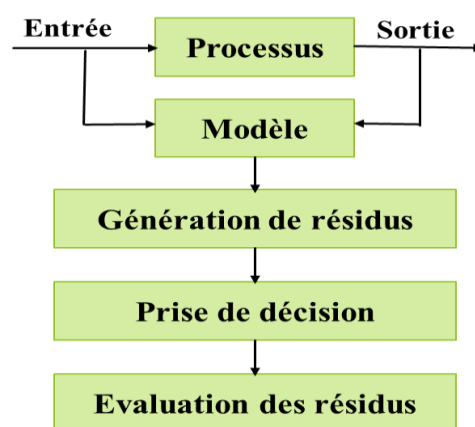


Fig.1.7- L'architecture générale d'un tel système de surveillance.

Dans la seconde étape, les résidus sont analysés pour décider la présence ou non de défaut, sur quel composant du processus il est intervenu (localisation) et, dans certains cas, déterminer la nature du défaut et sa cause (identification). L'évaluation des résidus n'est donc pas une tâche

triviale. Selon le cas, elle peut s'effectuer à l'aide d'un simple test de dépassement de seuil où elle doit être formulée dans un cadre statistique. D'un point de vue pratique, la logique de décision à seuils joue un rôle important car la plupart des méthodes citées dans la littérature se ramènent, à terme, à un seuillage. La valeur du seuil est souvent inspirée de l'expérience des opérateurs en tenant compte des spécifications propres au processus surveillé. Pour le besoin de la maintenance conditionnelle, et afin de détecter les dégradations lentes, des approches à seuils adaptatifs évoluant en fonction du point de fonctionnement du processus surveillé ont été envisagées pour certaines applications [19]. Les résultats d'évaluation sont ensuite utilisés pour émettre une décision appropriée. La figure (**Fig.1.7**) illustre l'architecture générale d'un tel système de surveillance.

L'algorithme de diagnostic repose essentiellement sur l'utilisation de modèle du système pour la génération des résidus, connus aussi sous le nom d'indicateurs de fautes. Ces derniers décrivent des relations analytiques comparant les dynamiques modélisées avec ceux mesurées d'un système physique. Parmi ces méthodes nous citons : Les observateurs, les Relations de Redondances Analytiques (**RRA**), et le filtrage. Les résidus sont théoriquement nuls en l'absence de défauts sur le système, des incertitudes paramétriques, des erreurs de mesures et des erreurs de modélisation. La procédure de diagnostic à base de modèles se résume en cinq étapes :

- 1- Synthèse du modèle dynamique du système ;
- 2- Génération des résidus ;
- 3- Détection du défaut ;
- 4- Isolation de défaut ;
- 5- Estimation du défaut.

En cas de défaut, les résidus sensibles divergent de leurs valeurs normales calculées en l'absence de défauts (zéro dans le cas idéal) ce qui permet la détection de ce défaut lorsque l'évolution de signal du résidu se fait en dehors des seuils de détection. L'isolation de défauts est effectuée en utilisant la signature obtenue à partir des résidus sensibles à chaque défaut.

L'existence des incertitudes paramétriques, des erreurs de mesures, et des erreurs de modélisation pourrait engendrer de fausses alarmes et/ou des situations de non détection du défaut. À ce propos, lorsque les incertitudes ne sont pas prises en considération, la confiance

sur la décision du système de diagnostic diminue. Dans le but de résoudre cette problématique, plusieurs méthodes robustes de détection de défauts (connues sous la terminologie anglaise **Robust Fault Detection and Isolation (RFDI)** ont été proposées dans la littérature. La plupart de ces méthodes visent à éliminer ou à minimiser les effets des incertitudes sur les résidus, tandis que d'autres ont recours au découplage entre la partie incertaine et la partie nominale de la relation de redondance analytique (**RRA**). Ce découplage permet de générer le seuil moyennant la valeur maximale relative à la partie incertaine.

1.9. Conclusion

Après une brève introduction dans laquelle nous avons décrit la problématique abordée et le contexte général du travail, nous avons présenté quelques méthodes de diagnostic, souvent utilisées dans la littérature, permettant de détecter les défaillances survenant au sein d'un système dynamique. Une attention particulière est portée aux méthodes à base de modèles sans oublier une revue rapide des méthodes sans modèle et d'analyse des risques. Les techniques à base de modèles, nécessitent une connaissance des dynamiques mises en jeu. Le diagnostic se fait ensuite en utilisant un certain nombre de signaux significatifs (résidus) générés à l'aide d'un modèle représentant le système à surveiller. Selon la représentation utilisée, plusieurs stratégies peuvent être imaginées à cet effet. Néanmoins, le développement d'un modèle mathématique n'est pas toujours facile à cause de différents facteurs tels que la complexité et les non-linéarités présentes dans la dynamique des processus. Une étape de modélisation sera donc nécessaire afin de définir un modèle de référence assez proche de la réalité et d'assurer un diagnostic fiable et robuste.

Bibliographies

- [1] **F. poitier**, *Etude et commande de génératrice asynchrone pour l'utilisation de l'énergie éolienne, université de nante*, 2003.
- [2] **AFNOR**, *NF X60-000, Maintenance industrielle, Fonction maintenance*, Mai 2002.
- [3] **S. BACHIR**, « *Contribution au diagnostic de la machine asynchrone par estimation paramétrique* », 2002.
- [4] **A. IBRAHIM**, « *Contribution au diagnostic de machines électromécaniques* », 2009.
- [5] **P. K.-S. B. Frank**, « *New developments using AI in fault diagnosis, Engineering. Applic. Artif. Intell.*, » vol. 10, n° 11, pp. 3-14, 1997.
- [6] **R. Isermann**, « *Fault-diagnosis systems : an introduction form fault detection to fault tolerance.*, » Springer,, 2006.
- [7] **V. R. K. Venkatasubramanian**, « *A review of process and fault detection.*, » *Computers & Chemical Engineering*,, vol. 27, pp. 293-346, 2003.
- [8] **S. METHNANI**, *Diagnostic, reconstruction et identification des défauts capteurs et actionneurs : application aux station d'épurations des eaux usées*,, 2012.
- [9] **M. Kamel**, *Estimation d'Etat et Diagnostic de Fonctionnement des Systèmes non Linéaires*,, 2010.
- [10] **J. N. Hakami**, « *An Application of ICLX in a British Steel Corporation Works.*, » *Expert Systems in Heavy Industry*,, n° 11, pp. 347-359.
- [11] **P. M. Frank**, *Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy - a survey and some new results*,, vol. 3, *Automatica* , pp. 459-474.
- [12] **R. Isermann**, *Process fault detection based on modeling and estimation methods*,, vol. 4, *Automatica*, 1984, pp. 387-404.
- [13] **T. Souad**, *Diagnostic Des Systèmes Dynamiques à Base D'observateurs à Entrées Inconnues*, *Thèse de doctorat* , 2015.
- [14] **E. a. T. j. X.Ding**, *an approach to analysis and design of observer and parity relation based FDI systems*,, vol. 14 th, *Ifac World congress*, 1997, pp. 37-42.
- [15] **M. staroswiecki**, *analyse structurelle, paris, france: edition hermes* , 2000, p. 32.
- [16] **F. busson**, *modélisation et surveillance des processus en génie des procédés à l'aide des bond graph Multiénergies*,, *thèse de doctorat lille1, france, decembre 2002*.
- [17] **J. d. Kleer**, *using crud probabilities estimate to guide diagnosis, proceedings of AAAI conference*, pp. 842-848.
- [18] **H. HACENE**, *Identification et Surveillance de Processus Dynamiques Complexes par Logique Floue*,, *thèse de doctorat* , 2007.
- [19] **F. RAMAHLEOMIARANTSOA**, *diagnostic des systemes a energies renouvelables de types eoliens*, 2013.

Chapitre II

Table des matières

2. Modélisation D'un Système Mécatronique Application Sur Un Système Eolien	31
2.1. Introduction	31
2.2. Concept fondamental de l'approche Bond Graph	31
2.3. Les transferts de puissance	32
2.4. Variables mises en jeu	32
2.5. Les éléments bond graphs.....	33
2.5.1. Eléments passifs simples	34
2.5.1.1. L'élément R	34
2.5.1.2. L'élément C	34
2.5.1.3. L'élément I	35
2.5.2. Eléments Actifs : les sources.....	36
2.5.2.1. Eléments de jonction	36
2.5.2.2. L'élément TF	37
2.5.2.3. L'élément GY	38
2.6. Notion de causalité	38
2.7. Procédure d'affectation de la causalité	39
2.8. Modélisation du système de production d'énergie de l'éolienne.....	39
2.8.1. Description du système	39
2.8.2. Modèle aérodynamique.....	40
2.8.3. Modèle de la partie mécanique	43
2.8.4. Backlash	47
2.8.5. Modèle de la partie électrique	48
2.8.6. La transformation de Park.....	49
2.9. Les résultats de simulations.....	51
2.9.1. Mise en œuvre du modèle de simulations.....	51
2.9.2. Paramètres du système	52
2.10. Discussions des résultats	59
2.11. Conclusion.....	59
Bibliographies	61

Modélisation d'un Système Mécatronique Application sur un Système Eolien

2

Le but de ce chapitre est de décrire les composants d'un système de conversion d'énergie éolienne à la base d'une génératrice asynchrone. Une étude en modélisation sur les différentes parties constituant une éolienne, en cite autre autres, la partie aérodynamique, la partie mécanique et la partie électrique est effectuée en utilisant l'approche Bond Graph. Une étude en simulation a été menée pour extraire les différentes réponses décrivant le comportement et l'évolution temporelle valider les modèles développés ainsi que leurs comportements vis-à-vis différents scénarios réalisés selon le niveau d'amplitude de niveaux de backlash.

2.1. Introduction

Il existe deux grandes familles d'éoliennes : celle à axe vertical et celle à axe horizontal. Actuellement, les éoliennes à axe horizontal sont largement plus utilisées que les éoliennes à axe vertical pour des raisons économiques liées à leur fabrication et à leur installation.

Parmi les éoliennes à axe horizontal, on distingue celles à vitesse fixe et celles à vitesse variable. Ces dernières sont les plus couramment utilisées pour la production d'énergie électrique sur le réseau électrique. En effet, les éoliennes à vitesse variable, contrairement aux éoliennes à vitesse fixe, fonctionnent sur une large plage de vitesses permettant ainsi une maximisation des puissances extraites pour de faibles vitesses du vent et le maintien d'une puissance constante pour des vitesses de vent élevées.

Ce chapitre a pour but de donner une description du système de l'éolienne et les différentes parties constituant une éolienne sont décrites de façon générale, puis une synthèse de l'approche Bond Graph est présentée. Ensuite, à la dernière partie de ce chapitre nous présentons la modélisation Bond Graph des différentes parties d'éolienne ainsi que le modèle complet.

2.2. Concept fondamentale de l'approche Bond Graph

La méthodologie de la modélisation par bond graph est basée sur la caractérisation des phénomènes d'échanges de puissance (par un lien) au sein d'un système. L'idée de la modélisation par bond graph est la représentation des puissances dissipées comme le produit Flux-effort et de les lier par les différentes jonctions pour reproduire le système.

Les bonds graphs permettent, à partir d'un système physique quelconque, d'obtenir une représentation graphique indépendante du domaine physique étudié.

Un bond graph est un graphe orienté, faisant apparaître des variables dynamiques, qui traduisent les transferts d'énergie entre systèmes. Ils sont basés sur les liens de puissance du type proposé sur la figure (Fig.2.1) :




Fig.2.1- Liens Bond graph.

Les variables $e(t)$ et $f(t)$ représentent respectivement l'effort et le flux entre les systèmes $S1$ et $S2$ dont le produit $P(t) = e(t)f(t)$ n'est rien d'autre que la puissance instantanée transférée entre $S1$ et $S2$. Les deux variables $e(t)$ et $f(t)$ sont dites conjuguées l'une de l'autre.

2.3. Les transferts de puissance

Un modèle bond graph est une représentation graphique de type réseau du système physique. Cette représentation est fondée sur l'hypothèse de réticulation qui permet une décomposition du système en un ensemble de sous-systèmes élémentaires échangeant de la puissance entre eux. Cette puissance est transmise de manière à assurer la conservation de l'énergie, mais aussi sa continuité [1]. Le transfert de puissance (ou flux d'énergie) entre deux sous-systèmes est représenté par une demi flèche qui correspond au « bond » du bond graph.

La puissance instantanée échangée se calcule par le produit d'une variable de flux f et d'une variable d'effort e indépendamment du domaine considéré. En mécanique par $P = FV$ ou en électricité par $P = ui$, le sens de la demi flèche est celui correspondant au sens positif de la puissance et de la variable de flux (Fig.2.2).




Fig.2.2- Représentation des transferts de puissance.

2.4. Variables mises en jeu

Deux types de variables sont utilisés dans la théorie bond graph indépendamment du domaine du physique considéré.

- Le premier type est constitué des variables de puissance. Les variables de puissance associées à chaque lien sont l'effort $e(t)$ et le flux $f(t)$;
- Le deuxième type concerne les variables d'énergie qui sont le moment généralisé $p(t)$ pour un élément I de type inertiel et le déplacement généralisé $q(t)$ pour un élément C de type capacitif.

Les variables d'énergie sont liées aux variables de puissance par les relations :

$$\text{Moment généralisé} \quad p(t) = \int_0^t e(\tau) d\tau + p(0) \quad (2.1)$$

$$\text{Déplacement généralisé} \quad q(t) = \int_0^t f(\tau) d\tau + q(0) \quad (2.2)$$

Elles sont également choisies comme variables d'état associées respectivement aux éléments I et C qui les font intervenir dans leurs relations caractéristiques. L'interprétation physique de chacune des variables généralisées est donnée par le domaine physique du système modélisé (Tableau 2.1).

Tableau 2.1 : Signification des variables généralisées pour quelques domaines physiques :

Domaine	Variables de Puissance		Variable d'énergie	
	Effort (e)	Flux (F)	Moment (P)	Déplacement (q)
Mécanique de translation	Force F	Vitesse v	Impulsion p	Déplacement x
Mécanique rotationnelle	Couple τ	Vitesse angulaire w	Impulsion angulaire h	Angle
Hydraulique	Pression P	Débit volumique q	Impulsion pression Γ	Volume
Electricité	Tension u	Courant i	Flux magnétique ϕ	Charge
Magnétique	Force magnétomotrice	Dérivée flux magnétique		Flux magnétique
Chimique	Potentiel chimique	Flux molaire		Masse molaire

2.5. Les Eléments bond graphs

Les éléments bond graphs peuvent se classier de la façon suivante :

- Eléments passifs : R, C, I ;
- Eléments actifs : Se, Sf ;
- Eléments de jonction : $0, 1, Tf, GY$.

2.5.1. Eléments passifs Simples

Les éléments R , C , I sont dits éléments passifs car ils transforment la puissance qui est leur fournie en énergie dissipée sous forme de chaleur (R), ou stockée (éléments C et I). La puissance est fournie aux éléments, ce qui impose d'orienter le sens de la demi-flèche du lien vers l'élément.

2.5.1.1. Elément R

L'élément R est utilisé pour modéliser tout phénomène physique liant la variable d'effort à la variable de flux dans le domaine physique considéré. A titre d'exemples, citons les résistances électriques, les éléments de commutation en électronique, les amortisseurs, les conduites, tout phénomène de frottement mécanique et les réactions chimiques. Il est caractérisé par la loi générique :

$$\Phi_R(e_R, f_R) = 0 \quad (2.3)$$

La représentation générale est :




Fig.2.3- Représentation générale d'un élément Bond graph.

On représente ainsi par R le type de phénomène identifié par $R1$ ou b la valeur du paramètre intervenant dans l'écriture de la loi linéaire. Dans le cas non linéaire, il est en générale difficile de spécifier la loi ; il est parfois possible d'indiquer comment varie le paramètre.

2.5.1.2. L'Elément C

L'élément C est utilisé pour modéliser tout phénomène physique liant la variable d'effort à la variable de déplacement dans le domaine considéré. A titre d'exemples, citons les condensateurs, les ressorts, les réservoirs hydrauliques. Il est caractérisé par la loi générique :

$$\Phi_C(e_C, f_C) = 0 \quad (2.4)$$

Ce qui donne par exemple, en linéaire :

$$u = \frac{1}{c_1} \int i dt \text{ Ou } u = \frac{q}{c_1} \text{ dans le domaine électrique} \quad (2.5)$$

$$F = k \int V dt \text{ Ou } F = kx \text{ dans le domaine mécanique} \quad (2.6)$$

La représentation générale d'un élément C'est :



Fig.2.4- Représentation générale de l'élément C.

C : C'est un élément de stockage d'énergie.

2.5.1.3. L'élément I

L'élément I est utilisé pour modéliser tout phénomène physique liant la variable de flux à la variable de moment dans le domaine physique considéré. A titre d'exemples, citons les bobines, les inductances, les masses en translation, l'inertie hydraulique et tout phénomène inertiel en mécanique. Il est caractérisé par la loi générique :

$$\Phi_I(e_I, f_I) = 0. \quad (2.7)$$

La représentation générale d'un élément I est :




Fig.2.5- Représentation générale de l'élément I.

I est un élément de stockage d'énergie.

2.5.2. Eléments Actifs : les Sources

Ces éléments sont dits éléments actifs car elles contribuent à fournir de la puissance au système. Ainsi, un générateur de tension (supposé idéal).

- Les sources d'effort Se (force de gravité, générateur de tension,)
- Les sources de flux Sf (vitesse appliquée, générateur de courant,)

L'orientation de la demi-flèche est fixée, elle est représentée sortante de la source.



Fig.2.6- Représentation générale des éléments Se et Sf .

La variable d'effort (pour Se) ou flux (pour Sf) fournie par la source est supposée indépendante de la variable complémentaire flux (pour Se) ou effort (pour Sf) qui dépend des caractéristiques du système et de la variable appliquée.

2.5.2.1. Eléments de jonction

Les éléments de jonction, notés 1 , 0 , TF et GY servent à coupler les éléments R , C , I et les sources, et composent la structure de jonction correspondant à l'architecture du modèle étudié. Ils sont conservatifs de puissance.

- **La jonction 0**

La jonction 0 sert à coupler des éléments soumis au même effort. Les relations qui la caractérisent sont :

$$e_1 = e_2 = \dots e_n \tag{2.8}$$

$$\sum_{i=1}^n a_i f_i = 0 \tag{2.9}$$




Fig.2.7- Représentation générale de la jonction 0.

• **La jonction 1**

La jonction 1 sert à coupler des éléments parcourus par le même flux. Les relations qui la caractérisent sont :

$$f_1 = f e_2 = \dots f_n \tag{2.10}$$

$$\sum_{i=1}^n a_i e_i = 0 \tag{2.11}$$




Fig.2.8- Représentation générale de la jonction 1.

Ces relations constitutives de la jonction 0 et 1 correspondent à la généralisation à tout domaine physique des lois de *Kirchhoff* en électricité (loi des nœuds, loi des mailles).

2.5.2.2. L'élément TF

L'élément *TF* est un élément 2-port, conservatif de puissance, il intervient dans la modélisation des transformateurs électriques, des leviers, des systèmes d'engrenages, des systèmes de poulies, ...etc. Il est aussi utilisé pour modéliser les changements de domaines physiques qui se font sans perte de puissance.



Fig.2.9- Transformateur TF et son équation constitutive.

Où *m* est le module de transformateur.

Les relations qui le caractérisent sont :

$$e_1 = m e_2 \tag{2.12}$$

$$f_2 = m f_1 \tag{2.13}$$

Si *m* n'est pas constant, le transformateur est modulé noté MTF. Cet élément est utilisé par exemple en mécanique (relations géométriques entre variables, réducteur variable, cinématique des mécanismes, ...).

2.5.2.3. L'élément GY

L'élément *GY* est aussi un élément 2-port, conservatif de puissance, il intervient dans la modélisation des gyroscopes, des capteurs à effet Hall. Il est aussi utilisé pour modéliser les changements des domaines physiques qui se font sans perte de puissance.



Fig.2.10- Gyrateur *GY* et son équation constitutive.

$$e_1 = r f_2 \tag{2.14}$$

$$e_2 = r f_1 \tag{2.15}$$

Ou *r* est le module du Gyrateur.

Si *r* est variable, l'élément est alors un Gyrateur modulé, noté *MGY*. Cet élément apparait en mécanique pour modéliser la dynamique d'un solide dans l'espace.

2.6. Notion de Causalité

L'ajout d'un trait perpendiculaire au lien indique la causalité qui exprime la relation de cause à effet entre les variables. Par convention, le trait causal est placé de la manière suivante :

1. Le trait causal est placé **près de l'élément** pour lequel **l'effort** est imposé ;
2. Le trait causal est placé **loin de l'élément** pour lequel **le flux** est imposé.




Fig.2.11- Notion de causalité.

La position du trait causal est tout à fait indépendante du sens de la demi-flèche.

2.7. Procédure d'affectation de la causalité

- Affectez la causalité obligatoire aux sources et aux éléments R non linéaires et répercutez sur l'environnement en respectant les restrictions de causalité des jonctions ;
- Affectez une causalité intégrale préférentielle aux éléments I et C et répercutez sur l'environnement en respectant les restrictions de causalité aux jonctions ;
- Complétez la causalité sur les éléments R linéaires en respectant les restrictions de causalité aux jonctions ;
- En cas de conflit à une jonction, recherchez l'élément I ou C cause de conflit et lui affectez une causalité dérivée. Bouclez sur l'étape 3.

2.8. Modélisation du système de production d'énergie éolienne

2.8.1. Description du système

L'éolienne est le système de conversion d'énergie du vent en énergie électrique, de nos jours, l'énergie éolienne est devenue une solution fiable pour la production d'énergie, en complément des autres sources d'énergie renouvelables, On peut considérer trois composants essentiels dans une éolienne, la nacelle, le rotor, et le mât, [2] comme elles sont illustrées sur la figure (Fig.2.12), [3].

- **Un mât (ou tour)** qui permet de placer l'éolienne à une hauteur où la vitesse du vent est plus élevée et plus régulière qu'au sol. Pour être rentables, les premières installations d'éolienne domestique démarrent à 10 mètres. Les professionnels conseillent cependant des mâts d'éoliennes domestiques plus hauts pour maximiser la production ;




Fig.2.12- Les principaux composants d'une éolienne [3].

- **Une nacelle**, au sommet du mât, équipé **d'un rotor** à axe horizontal, avec **deux ou trois pales** mises en rotation par le vent. Dans le cas du petit éolien domestique, le diamètre des pales varie de 2 à 10 mètres. Le vent fait tourner les pales de l'éolienne. Le mouvement de rotation est alors converti par le rotor en électricité ;
- **La transmission mécanique** qui transforme le mouvement de rotation du rotor en un mouvement utilisable par la charge ;
- **Une génératrice électrique** qui transforme l'énergie mécanique en énergie électrique.




Fig.2.13- Modèle de l'éolienne.

2.8.2. Modèle aérodynamique

Le rotor de la turbine éolienne transforme l'énergie cinétique absorbée de vent en puissance mécanique. La puissance dans le vent est proportionnelle au cube de la vitesse du vent et peut être décrite comme :

$$P_{vent} = \frac{1}{2} \rho \pi R^2 v^3 \quad (2.16)$$

Avec :

ρ : la masse volumique de l'air (approximativement $1,225 \text{ kg/m}^3$ à la pression atmosphérique et à 15°C), R : le rayon du cercle décrit étant défini par la longueur d'une pale, v : la vitesse du vent.

Pour déterminer la puissance extraite par un rotor de turbine à vent, le modèle Betz (1926) est largement utilisé. Le modèle Betz est non seulement utilisé pour trouver la puissance d'un rotor de turbine idéal. Mais aussi de trouver la poussée du vent sur le rotor idéal et l'effet du fonctionnement du rotor sur le champ de vent local. Ce modèle simple est basé sur la théorie de la quantité de mouvement. L'analyse suppose un volume de contrôle dont les frontières sont la surface d'un tube de courant et de ses deux sections transversales.

La turbine de l'analyse est représentée par n disque d'actionnement uniforme ou convertisseur qui crée une discontinuité de pression dans le tube de courant d'air qui le traverse. L'analyse de Betz suppose en outre que [4]:

- L'air est homogène, incompressible et atteint un écoulement de fluide à l'état stable ;
- Il n'y a pas de résistance de frottement ;
- Nombre de pales sur le rotor est infini ;
- Poussée uniforme se produit sur la surface de disque ou rotor.

Une éolienne ne peut extraire qu'une partie de la puissance du vent. Le rapport de la puissance $C_p(\beta, \lambda)$ extraite du vent est une fonction non linéaire de l'angle de pas de pale β et du rapport de vitesse de pointe λ . Par conséquent, la puissance mécanique de l'éolienne extraite du vent peut être exprimée [5] :

$$P_{mech} = \frac{1}{2} \rho \pi R^3 v^3 C_p(\beta, \lambda) \quad (2.17)$$

Avec : $\lambda = \frac{R\Omega_{wt}}{v}$.

Ω_{wt} : La vitesse de rotation de la turbine




Fig.2.14- profile du vent.

Depuis [6] le couple aérodynamique C_a et la force de poussée agissant sur la tour de l'éolienne est :

$$C_a = \frac{1}{2} \rho \pi R^3 v^3 C_p(\beta, \lambda) \quad (2.18)$$

$$F_T = \frac{1}{2} \rho \pi R^2 v^2 C_T(\beta, \lambda) \quad (2.19)$$

Sachant que $C_T(\beta, \lambda)$ est le coefficient du couple défini par :

Le coefficient de puissance C_p représente le rendement aérodynamique de la turbine éolienne et dépend également de la caractéristique de la turbine. Ce coefficient présente une limite théorique, appelée limite de Betz, égale à 0,593 et qui n'est jamais atteinte en pratique. Dans le cadre de cette thèse, nous utiliserons une expression approchée du coefficient de puissance en fonction de la vitesse relative λ et de l'angle de calage des pales β dont l'expression a pour origine les travaux de [7] :

$$C_p(\lambda, \beta) = \frac{P_m}{\frac{1}{2} \rho A v^3} \quad (2.20)$$

Des approximations numériques ont été développées dans la littérature pour calculer le coefficient C_p et différentes expressions ont été proposées, dans notre étude nous avons utilisé la formule :

$$C_p(\lambda, \beta) = c_1 \left(\frac{c_2}{\lambda_i} - c_3 \beta - c_4 \right) e^{\frac{c_5}{\lambda_i}} + c_6 \lambda \quad (2.21)$$

Connaissant la vitesse de rotation de la turbine, le couple mécanique T_m disponible sur l'arbre lent de la turbine peut donc s'exprimer par :

$$T_m = \frac{1}{2} \cdot \rho \cdot \pi \cdot R^3 C_T(\lambda, \beta) \cdot v^2 \quad (2.22)$$

$$\lambda_i = \frac{1}{\frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^2 + 1}} \quad (2.23)$$

Avec $c_1 = 0.22$, $c_2 = 116$, $c_3 = 0.4$, $c_4 = 5$, $c_5 = 0.0068$.

Pour différentes valeurs de l'angle de calage, le coefficient de puissance est montré sur la figure (**Fig.2.15**).




Fig.2.15- Coefficient de puissance pour différentes valeurs de β .

Le modèle de simulation de la partie aérodynamique développé sous le logiciel 20-sim et présenté sous la figure (Fig.2.16) :

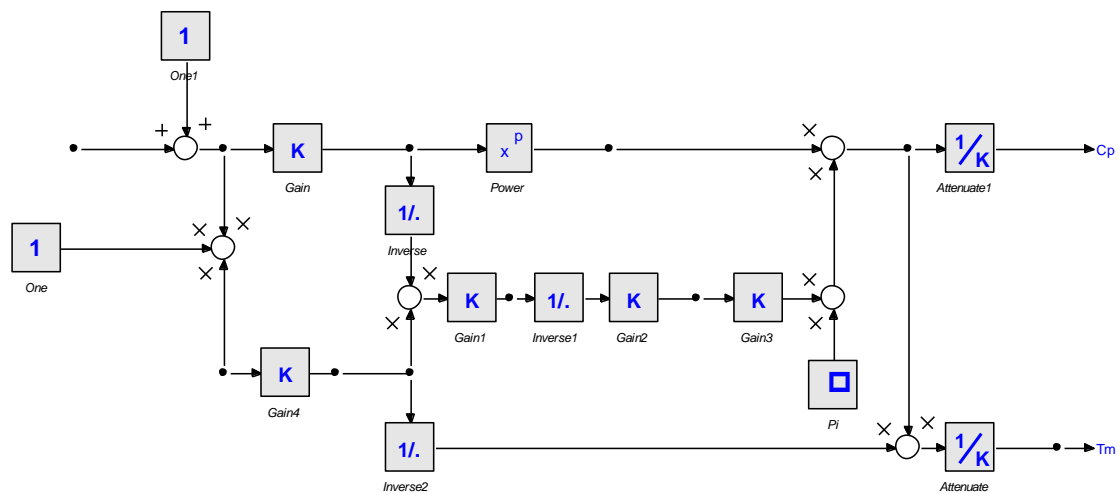


Fig.2.16- modèle de la partie aérodynamique sous 20-sim.

2.8.3. Modèle de la partie mécanique

La partie mécanique de la turbine comprend trois pales orientables et de longueur R . Elles sont fixées sur un arbre d'entraînement tournant à une vitesse de rotation Ω_{wt} , relié à

un multiplicateur de gain G . Ce multiplicateur entraîne la génératrice électrique. Les trois pales sont considérées identiques. De plus, on considère une répartition uniforme de la vitesse du vent sur toutes les pales et donc une égalité de toutes les forces de poussée. Ainsi, on peut modéliser l'ensemble des trois pales comme un seul et même système mécanique caractérisé par la somme de toutes les caractéristiques mécaniques. De par la conception aérodynamique des pales, nous considérons que leur coefficient de frottement par rapport à l'air est très faible et peut être négligé. De même, la vitesse de la turbine étant très faible, les pertes par frottement seront négligeables devant les pertes par frottement du côté de la génératrice. Sur la base de ces hypothèses, on obtient alors un modèle mécanique constitué de deux masses comme l'illustre la figure (Fig.2.17) dont la validité, par rapport au modèle complet de la turbine, a déjà été vérifiée [8].




Fig.2.17- Modèle mécanique de l'éolienne.

Avec :

- J_{wt} : le moment d'inertie de la turbine équivalent aux inerties des trois pales de l'éolienne ;
- J_{gen} : le moment d'inertie de la MAS ;
- B_{wt}, B_{gen} : Les coefficients dû aux frottements visqueux de la turbine et la MAS ;
- T_m : Le couple mécanique sur l'arbre de la MAS ;
- Ω_{gen} : La vitesse de rotation de la MAS ;
- J_{wheel1}, J_{wheel2} : Les moments d'inertie des disques à engrenage constitue le multiplicateur.

Le multiplicateur adapte la vitesse de rotation de la turbine (arbre lent) à la vitesse de rotation de la MAS (arbre rapide) (Fig.2.17). En considérant que le multiplicateur est idéal, c'est-à-dire que les pertes mécaniques sont négligeables, il est alors modélisé par les deux équations :

$$\Omega_{gen} = G \cdot \Omega_{wt} \quad (2.24)$$

$$T_m = G T_{wt} \quad (2.25)$$

avec G le gain de multiplicateur de vitesse.

La transmission de puissance est composée de l'inertie du rotor de la turbine et de l'inertie de la génératrice. Le modèle mécanique équivalent proposé intègre ces deux inerties [9].

$$J = \frac{J_{wt}}{G^2} + J_{gen} \quad (2.26)$$

Il est à noter que l'inertie du rotor de la génératrice est très faible par rapport à l'inertie de la turbine reportée par cet axe.

L'équation fondamentale de la dynamique qui permet de déterminer l'évolution de la vitesse mécanique à partir du couple mécanique T_m est défini par :

$$J \frac{d\Omega_{gen}}{dt} = T_m \quad (2.27)$$

Avec J est l'inertie totale qui apparaît sur le rotor de la génératrice. Ce couple mécanique prend en compte, le couple électromagnétique C_e produit par la génératrice, le couple des frottements visqueux C_{vis} et le couple C_r issu du multiplicateur.

$$T_m = C_r - C_e - C_{vis} \quad (2.28)$$

Avec :

$$C_{vis} = f \Omega_{gen} \quad (2.29)$$

f est le coefficient du frottement équivalent de l'arbre égale à :

$$f = \frac{f_t}{G^2} + f_g \quad (2.30)$$

Ou f_t et f_g sont les coefficients de la turbine et du générateur respectivement.

Le modèle de l'éolienne présenté à la figure (Fig.2.17) est un modèle à trois masses (la masse de rotor de la turbine, la masse de multiplicateur de vitesse et la masse de la génératrice), l'équation dynamique de l'arbre lent est :

$$T_{wt} - T_l - B_{wt} \Omega_{wt} = J_{wt} \frac{d\omega_{wt}}{dt} \tag{2.31}$$

L'équation dynamique de l'arbre rapide est :

$$T_h - T_{gen} - B_{gen} \Omega_{gen} = J_{gen} \frac{d\Omega_{gen}}{dt} \tag{2.32}$$

Avec :

$$T_l(t) = K_{wt} \left(\theta_r - \frac{\theta_{gen}}{K_{gear}} \right) + D_{wt} \left(\Omega_{wt} - \frac{\Omega_{gen}}{K_{gear}} \right) \tag{2.33}$$

Après substitution d'équation 2.17 dans l'équation 2.15 et simplification on obtient :

$$\left\{ \begin{array}{l} J_{wt} \frac{d\omega_{wt}}{dt} = T_{wt} - K_{wt} \left(\theta_r - \frac{\theta_{gen}}{K_{gear}} \right) - (D_{wt} + B_{wt}) \Omega_{wt} + \frac{D_{wt}}{K_{gear}} \Omega_{gen} [Nm] \\ J_{gen} \frac{d\omega_{gen}}{dt} = \frac{K_{wt}}{K_{gear}} \left(\theta_r - \frac{\theta_{gen}}{K_{gear}} \right) + \frac{D_{wt}}{K_{gear}} \Omega_{wt} - \left(\frac{D_{wt}}{K_{gear}} + B_{gen} \right) \Omega_{gen} - T_{gen} [Nm] \\ \dot{\theta}_r = \dot{\theta}_{wt} - \frac{\dot{\theta}_{gen}}{K_{gear}} [rad / s] \end{array} \right. \tag{2.34}$$

La figure (Fig.2.18) montre la modélisation du système à trois masses sous 20-sim :

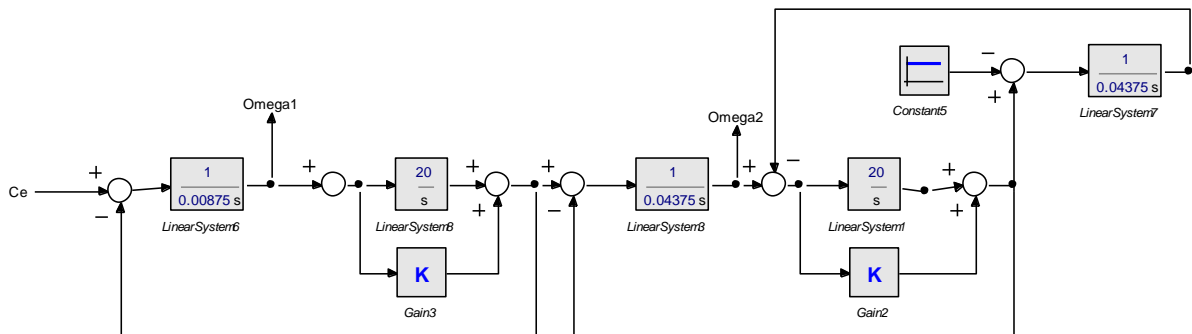


Fig.2.18- Modèle à Trois masses sous le logiciel 20-sim.

2.8.4. Backlash

Le problème le plus sérieux dans la modélisation du backlash est le contact des dents, lorsque l'engrenage devient actionneur et vice-versa. La force de réaction dans ce phénomène a été modélisée de différentes manières dans la littérature [10]. Dans ce travail, la force de réaction des dents d'engrenage, F_r , est composée de deux composantes non linéaires: la force élastique, F_k , et la force d'amortissement, F_c .




Fig.2.19- Backlash Mécanisme.

Le contact se produira lorsque les engrenages traverseront l'espace de jeu (Fig.2.19), comme le montre l'équation :

$$|dx| = |R_1\theta_{gen} - R_2\theta_{wt}| \geq d/2 \tag{2.35}$$

Initialement, le premier engrenage est placé au centre de l'espace vide entre deux dents du deuxième engrenage au point de départ. Le côté gauche de l'équation 2.35 exprime la différence entre les distances linéaires des deux engrenages à partir du point de départ dx . La valeur de la force élastique non linéaire dépend de la position relative des engrenages et est représentée sur la figure (Fig.2.20).




Fig.2.20- la force élastique non linéaire.

2.8.5. Modèle de la partie électrique

On distingue deux approches de modélisation pour la machine asynchrone : d'un côté, les modèles qui utilisent le repère naturel (abc) et d'autre côté, les modèles avec l'utilisation de la transformation de Park. Le choix de modèle dépend du type d'analyse qu'on veut faire sur le système.

Le modèle de la machine asynchrone est développé à partir du circuit électrique équivalent de la machine asynchrone figure (Fig.2.21).




Fig.2.21- Circuit équivalent de machine asynchrone.

La machine est vue depuis un repère généralisé ou arbitraire dq tournant autour de l'axe homopolaire O (orienté avec l'axe de la machine) à la vitesse $\omega_s(t) = d\varphi_s/dt$, où $\varphi_s(t)$ est la position angulaire de l'axe d du repère. Le moteur choisi est un moteur à cage avec un stator de p paires de pôles connecté en étoile (ce qui entraîne l'annulation des grandeurs homopolaires), avec une hypothèse de linéarité magnétique, une distribution spatiale sinusoïdale du champ magnétique dans un entrefer homogène, et en supposant négligeables les phénomènes d'hystérésis et les courants parasites.

Nous présentons une modélisation Bond Graph d'une machine asynchrone dans un repère de Park lié au vecteur de tension. Une machine asynchrone peut être représentée par trois enroulements identiques au stator. Le rotor à cage est ici également caractérisé par trois enroulements symétriques. De plus on suppose que la machine n'est pas saturée. L'équation de la machine s'écrit alors sous la forme suivante :

$$\begin{aligned}
 v_{sd} &= R_s i_{sd} + \frac{d\phi_{sd}}{dt} - \omega_s \phi_{sq} \\
 v_{sq} &= R_s i_{sq} + \frac{d\phi_{sq}}{dt} + \omega_s \phi_{sd} \\
 v_{s0} &= R_s i_{s0} + \frac{d\phi_{s0}}{dt} \\
 v_{rd} &= R_r i_{rd} + \frac{d\phi_{rd}}{dt} - \omega_r \phi_{rq} \\
 v_{rq} &= R_r i_{rq} + \frac{d\phi_{rq}}{dt} + \omega_r \phi_{rd} \\
 v_{r0} &= R_r i_{r0} + \frac{d\phi_{r0}}{dt}
 \end{aligned} \tag{2.36}$$

2.8.6. La transformation de Park

La transformation de Park nous permet de transformer les grandeurs d'un système triphasé en un système diphasé équivalent. Cette transformation est basée sur le théorème de Ferrari [11].

Comme présenté dans [12], la relation entre les grandeurs d'un système triphasé et d'un système diphasé équivalent est montrée à la figure (Fig.2.22) :




Fig.2.22- Relation entre un système triphasé et un système diphasé équivalent.

Il existe plusieurs transformations de Park mais celle qui a été utilisée dans la suite de ce travail est la transformation qui conserve la puissance (Fig.2.23). Cette dernière est définie ci-après :

$$\begin{bmatrix} X_d \\ X_q \\ X_0 \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} \cos\varphi & \cos(\varphi - \frac{2\pi}{3}) & \cos(\varphi - \frac{4\pi}{3}) \\ -\sin\varphi & -\sin(\varphi - \frac{2\pi}{3}) & -\sin(\varphi - \frac{2\pi}{3}) \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \\ X_3 \end{bmatrix} \quad (2.37)$$

Où φ indique l'angle entre l'axe d et la phase 1 du stator.

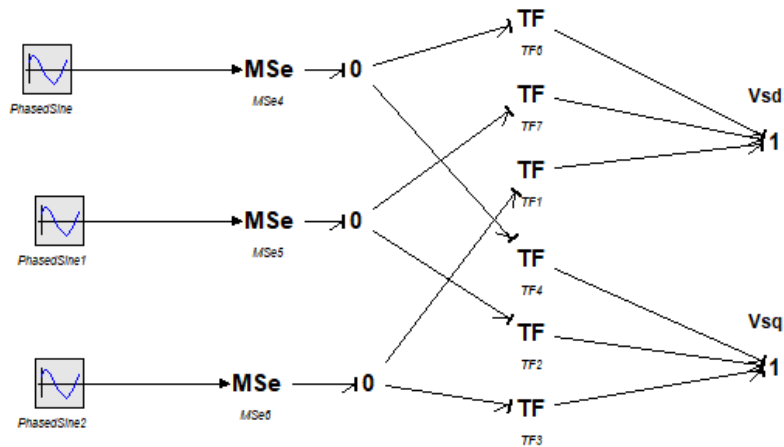


Fig.2.23- Modèle Bond Graph de la transformée de Park.

Le choix de modèle de la machine asynchrone doit être linéarisé au moins autour un point de fonctionnement c'est pour cela on a choisi le modèle dans un repère tournant. En effet dans ce cas les variables (effort, flux) véhiculées par le Bond Graph évoluent de façon continue et ce modèle peut être linéarisé autour d'un point de fonctionnement.

Le modèle de la machine asynchrone dans le repère dq est présenté dans la figure (Fig.2.24) :

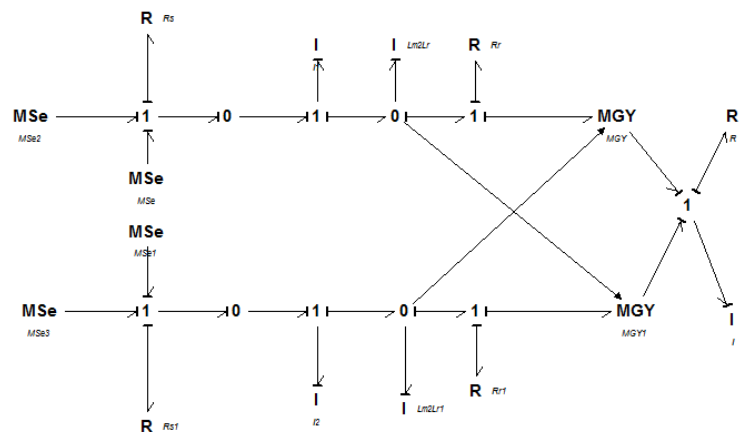


Fig.2.24- Modèle de la machine asynchrone sous 20-sim.

- 2- La partie mécanique constituée par le gearbox ;
- 3- La partie aérodynamique.




Fig.2.26- Schéma synoptique du système éolien sous 20-Sim.

2.9.2. Paramètres du système

Les paramètres du système mis en œuvre sont illustrés dans le tableau ci-dessous.

Tableau 2.2 : Paramètres du système utilisé dans 20-Sim :

Fréquence	50 Hz
Puissance nominal	$P_n=180\text{KW}$
Diamètre de rotor	$D=23.2\text{m}$
Vitesse de rotor	$\Omega=42\text{tr/min}$
Coefficient de multiplication	23.75
Nombre de pale	3
Densité de l'air	$\rho=1\text{Kg/m}^3$
Moment d'inertie de la turbine	$J_T=102,8\text{Kg}\cdot\text{m}^2$

Moment d'inertie de la génératrice	$J_G=4,5\text{Kg}\cdot\text{m}^2$
Coefficient rigidité	$K_{12}=2700\text{Nm/rad}$
Coefficient amortissement	$B_{12}=0.1\text{Nms/rad}$
Nombre de pair	$P=3$
Résistance de stator	$R_s=0.0092\Omega$
Résistance de rotor	$R_r=0.0061\Omega$
Inductance mutuelle stator	$L_{ls}=186\mu\text{H}$ ($L_s= L_{ls}+ L_m$)
Inductance mutuelle rotor	$L_{lr}=427\mu\text{H}$ ($L_r= L_{lr}+ L_m$)
Inductance magnétisme	$L_m=6.7\text{mH}$ ($L_{sr}= L_m$)

Pour valider ce système nous avons adopté plusieurs scénarios selon les cas suivants :

Tableau 2.3 : les scénarios de simulation :

Scénario	Backlash (rad)
1	$J_0=0$
2	$J_0=0.1$
3	$J_0=0.2$
4	$J_0=0.4$

• Cas-1 : Magnitude de backlash $J_0=0$ rad (cas sain) ;




Fig.2.27- Healthy system response: (a) Electromagnetic torque, (b) Low speed, (c) High speed, (d) Power coefficient, (e) Mechanical power, (f) Mechanical torque.

• Cas-2 : Magnitude de backlash $J_0=0.1$ rad ;




Fig.2.28- System response with $J_0=0.1$ rad : (a) Electromagnetic torque, (b) Low speed, (c) High speed, (d) Power coefficient, (e) Mechanical power, (f) Mechanical torque .

• Cas-3 : Magnitude de backlash $J_0=0.2$ rad ;




Fig.2.29- System response with $J_0=0.2$ rad : (a) Electromagnetic torque, (b) Low speed, (c) High speed, (d) Power coefficient, (e) Mechanical power, (f) Mechanical torque .

• Cas-4 : Magnitude de backlash $J_0=0.4$ rad ;




Fig.2.30- System response with $J_0=0.4$ rad : (a) Electromagnetic torque, (b) Low speed, (c) High speed, (d) Power coefficient, (e) Mechanical power, (f) Mechanical torque .




Fig.2.31- Residuals generation at $J_0=0.2$ rad on Eletromagnetic torque, Low speed and high speed between healthy and faulty system.




Fig.2.32- Residuals generation at $J_0=0.4$ rad on Eletromagnetic torque, low speed and high speed between healthy and faulty system.

2.10. Discussions des Résultats

La figure (Fig.2.26) représente le système éolien à trois masses sous le logiciel 20-sim. Le premier scénario a été exécuté dans un mode de fonctionnement sain (Fig.2.27). Les résultats de simulations montrent clairement la netteté de la réponse du système au niveau des différents points de mesure, on cite entre autres, le couple électromagnétique, le couple mécanique, les vitesses de rotation Ω_1 et Ω_2 et le coefficient de puissance.

Cependant, la figure (Fig.2.28) illustre un cas défectueux avec une amplitude de backlash $J_0=0.1 \text{ rad}$. Dans ce cas, l'influence de ce phénomène commence à apparaître au niveau des points de mesures cités précédemment. Cette influence se manifeste sous forme des fluctuations au niveau de l'amplitude et se traduit en harmonie au niveau de la pollution électrique. Pour bien illustrer ce phénomène, nous avons augmenté l'amplitude du défaut de backlash avec $J_0=0.2 \text{ rad}$ et $J_0=0.4 \text{ rad}$. Les résultats de simulation ont montré d'une façon significative l'importance de l'altération de ce défaut sur la qualité de l'énergie issue d'un système éolien (Fig.2.29 et Fig.2.30).

La phase d'analyse du phénomène de backlash a été effectuée en utilisant la comparaison entre un cas sain et un cas défectueux en évaluant les résidus. Les figures (résiduelles) illustrent l'erreur entre les différents modes de fonctionnement et montrent clairement la gravité du phénomène de backlash. Durant la troisième phase de diagnostic, nous avons utilisé une analyse spectrale en utilisant une fonction d'évaluation calculée à la base des niveaux (Fig.2.31 et Fig.2.32).

2.11. Conclusion

La modélisation est une étape très importante dans un schéma de diagnostic, car les performances recherchées de détection et d'isolation de fautes dépendent fortement de la précision du modèle.

Dans ce chapitre Nous avons présenté un état de l'art sur les différents parties qui constituent une éolienne (partie aérodynamique, partie électrique et partie mécanique), ainsi que la présentation du modèle de système de production d'énergie de l'éolienne avec l'approche Bond Graph qui est validée dans [5]. Le choix de l'outil bond graph pour le diagnostic, est dû à son aspect énergétique et multi physique.

Dans ce chapitre, nous avons décrit les trois parties essentielles de système de conversion éolienne avec leurs modélisation Bond Graph, la première représente la partie

Aérodynamique qui contient la turbine, la partie mécanique qui contient le multiplicateur et l'arbre de la MAS et la partie électrique qui contient la génératrice MAS.

À la fin de ce chapitre un scénario de simulation avec les résultats obtenues sous le logiciel 20-sim est présenté.

Bibliographies

- [1] **H. Paynter**, "analysis and design of engrenning System MIT," Press, 1961.
- [2] **Z. NAZIHA**, "Modélisation et optimisation multi objectifs d'une éolienne à axe horizontal d'un système de production éolien isolé de petite taille," 2005.
- [3] "<https://fr.wikidia.org/wiki/%C3%89olienne>," wikipedia, 11 02 2008. [Online]. Available: <https://fr.wikidia.org/wiki/%C3%89olienne>.
- [4] **S. R. M. F. P. e. N. A. I. Panos M.Pardalos**, *Handbook of Wind Power Systems*, Springer.
- [5] **A. Ramdane, A. Lachouri and M. Krikeb**, "modeling and simulation of a wind turbine driven induction generator using Bond Graph," *Journal of renewable Energy and Sustainable developement (RESO) ISSN2356-8569*, Vols. 1, Issue 2, 2015.
- [6] **A. Khaouch and Al**, "Mechatronic Design of An Electromechanical Pitching System for More Realistic Load Simulations of Wind Turbines by Means of the Bond Graph Methodology," *Journal of Chemical, Biological and Physical Sciences*, vol. Vol. 7, no. No. 2, pp. 223-246, 2017.
- [7] **S. R. a. Al**, "Modélisation de systèmes électromécaniques multi-masses à base de machines asynchrones, à l'aide des outils achines asynchrones, à l'aide des outils éoliennes," *École Polytechnique de Montréal, EPM-RT-2004-04*, 2004.
- [8] **A. Ramdane and A. Lachouri**, "study on the influence of backlash phenomena on wind turbine power by using bond graph approach," *journal of the Barazilian society of mechanical sciences and engineering*, vol. 10 issue 2, no. 91, pp. 1678-5878, 2017.
- [9] **M. SMAILLI**, "Modélisation et commande d'un aérogénérateur à machine asynchrone à double alimentation en vue de simulation des problèmes de cogénération," 2013.
- [10] **Kalantari.A and M. S. foomani**, "backlash nonlinearity modeling and adaptive controller design for an electromechanical power transmission system," *scientia iranica mechanical engineering*, vol. 16, no. 6, pp. 463-469, 2009.
- [11] **X. Roboam**, "De la modélisation à la commande des machines asynchrones, Note interne LEEI," 1996.
- [12] **G. GANDANEGARA**, "Méthodologie de conception systémique en Génie Electrique à l'aide de l'outil Bond Graph Application à une chaîne de traction ferroviaire," *Thèse*, 2003.

Chapitre III

Table des matières

3. Technique D'analyse Spectrale pour la Détection du Défaut Backlash ..	62
3.1. Introduction	62
3.2. Méthodes non paramétriques.....	63
3.2.1. Le périodogramme et le corrélogramme.....	63
3.2.2. Propriétés du corrélogramme	67
3.3. Méthodes paramétriques	68
3.3.1. Modèle AR (Autorégressif).....	68
3.3.2. Modèle AM (Moyenne Mobile)	69
3.3.3. Modèle ARMA (Auto Régressif à Moyenne Mobile)	70
3.4. Analyse Spectrale Haute Résolution.....	72
3.4.1. Méthode de Prony	72
3.4.2. Méthode de Pisarenko.....	75
3.4.3. Méthode de Burg pour l'estimation des paramètres.....	76
3.4.4. Méthode MUSIC	77
3.4.5. Méthode des vecteurs propres EV	77
3.4.6. Méthode de Norme Minimale MN	78
3.5. Les résultats de simulations.....	80
3.5.1. Etude en simulation pour les méthodes non paramétriques	80
3.5.1.1. Méthode de Périodogramme :	80
3.5.1.2. Méthode de Spectrogramme :	93
3.5.2. Méthode d'analyse spectrale paramétriques	106
3.6. Conclusion.....	114
Bibliographies	115

Technique d'analyse Spectrale pour la Détection du Défaut Backlash 3

La surveillance par analyse spectrale consiste à effectuer une simple transformée de Fourier des grandeurs affectées par le défaut, et à visualiser les fréquences parasites constituant la signature d'un défaut. Les grandeurs choisies sont soit les grandeurs électriques, soit les grandeurs mécaniques. Plusieurs méthodes de traitement du signal ont été développées. Les plus utilisées dans le domaine industriel sont celles basées sur l'estimation de la Densité Spectrale de puissance (DSP). Dans cette optique, on a développé des méthodes d'analyse spectrale paramétrique et non paramétrique ou encore à haute résolution pour pouvoir discriminer l'état défectueux par rapport à un état sain. Les résultats de simulation ont prouvé l'efficacité des hypothèses prévues dans le cahier des charges.

3.1. Introduction

La première étape de la méthode de surveillance automatique est l'analyse individuelle de chacun des signaux. Un signal est un vecteur porteur d'information. Ce vecteur peut prendre plusieurs formes, qu'elles soient analogiques ou numériques. Si l'analyse ou le traitement d'un signal peut être fait de manière analogique, le niveau technologique et les outils dont nous disposons aujourd'hui rendent le traitement numérique des signaux bien plus simple, rapide et efficace. Ainsi, un signal analogique (comme un signal vibratoire ou un signal de parole) sera tout d'abord numérisé avant analyse.

L'analyse spectrale recouvre l'ensemble des techniques permettant de passer du domaine temporel au domaine fréquentiel. Ce passage permet de passer d'une représentation des variations du signal en fonction du temps à la représentation des proportions du signal appartenant à telle ou telle bande fréquentielle. Cette dernière représentation correspond à la densité spectrale du signal, plus communément appelée spectre.

Dans la pratique, les signaux utilisés dans ce manuscrit sont bruités et comportent donc une part d'aléatoire. Cependant, les signaux sont acquis pendant un temps fini. Nous n'avons donc accès qu'à une réalisation de taille finie du signal. En conséquence, le calcul de la densité spectrale n'est pas possible ; seule une estimation du spectre est envisageable.

L'estimation de la densité spectrale d'un processus aléatoire est un problème rencontré dans différents domaines d'applications. Appliqué au domaine du traitement de signal, le problème consiste en l'estimation des fréquences et des amplitudes des sinusoïdes en milieu bruité [1]. En effet, l'analyse spectrale est une façon élégante de visualiser le contenu. Les méthodes traditionnelles telles que le périodogramme aussi bien que les méthodes basées sur la transformée de Fourier souffrent d'importantes limitations parmi lesquelles l'apparition des lobes secondaires dues au fenêtrage effectué sur le signal ; ce qui se traduit par une difficulté à discerner des fréquences rapprochées d'un signal sous une autre forme qui permet de mieux caractériser les signaux complexes. Différentes techniques existent, qui se distinguent par leur capacité à détecter des fréquences très rapprochées. Ces techniques sont qualifiées par résolution spectrale [2].

L'analyse spectrale consiste à associer à un signal $x(t)$ une fonction $P(f)$ appelée Densité Spectrale de Puissance (**DSP**). En théorie, la **DSP** d'un signal est la transformée de Fourier de sa fonction d'autocorrélation, et l'estimer revient donc à estimer l'autocorrélation du signal $x(t)$. En pratique, il y a deux difficultés majeures :

- Le nombre de données pour estimer $P(f)$ est toujours très limité ;
- Le signal $x(t)$ est généralement bruité.

De très nombreuses méthodes d'estimation spectrale existent dans la littérature [3]. Ces méthodes traitent des données acquises de façon uniforme ou non. Généralement regroupées en deux grandes familles. La première contient des méthodes dites classiques ou non paramétriques. Elle n'utilise aucune connaissance a priori sur le signal mise à part les observations de ce dernier. La seconde contient des méthodes dites paramétriques. Cette dernière utilise un modèle paramétrique décrivant le signal, modèle à partir duquel il est facile d'obtenir une estimation de la densité spectrale de puissance. Les paramètres du modèle sont adaptés en fonction des données recueillies. Dans cette partie du document, les différentes méthodes d'analyse spectrale (Méthodes paramétriques et non paramétriques) sont présentées.

3.2. Méthodes non paramétriques

Considérons un processus discret $\{x(n)\}_{n \in \mathbb{Z}}$ aléatoire stationnaire du second ordre de moyenne nulle et dont la fonction d'autocorrélation est :

$$r_{xx}(m) = E[x^*(n)x(n+m)] = r_{xx}^*(-m) \tag{3.1}$$

Sous les hypothèses de signaux stationnaires et ergodiques, la densité spectrale de puissance est définie par :

$$S_x(f) = \sum_{m=-\infty}^{\infty} r_{xx}(m) \exp(-j2\pi f m T) = \lim_{n \rightarrow \infty} E \left[\frac{1}{N} \left\| \sum_{n=0}^{N-1} x(n) \exp(-j2\pi f n T) \right\|^2 \right] \tag{3.2}$$

On suppose de N échantillons $\{x(n)\}_{n=0}^{N-1}$ du signal $x(t)$ pris aux instants uniformes $\{t_n = nT\}_{n=0}^{N-1}$, avec T la période d'échantillonnage. Nous cherchons à estimer la densité spectrale de puissance de $x(t)$ à partir de ces données. Il existe deux grandes classes d'estimations non paramétriques ou classiques du spectre, chacune étant liée à l'une des égalités dans l'équation (3.2) : le périodogramme et le corrélogramme.

3.2.1. Le périodogramme et le corrélogramme

Il existe deux familles principales d'estimateurs de la **DSP** à base de la transformée de Fourier : le **périodogramme** et le **corrélogramme**. Ils suivent le principe présenté par la figure (Fig.3.1) basé sur le théorème de Bochner-Khinchine.

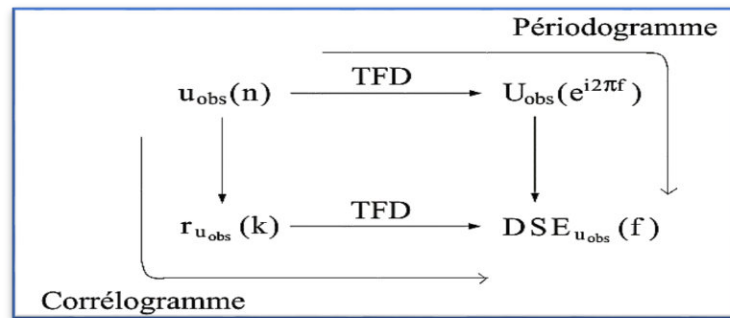


Fig.3.1- Principes du périodogramme et du corrélogramme.

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

$$P(f) = \int_{-\infty}^{+\infty} r_{xx}(\tau) e^{-j2\pi f \tau} d\tau \tag{3.3}$$

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

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

$$r(0) = E[x(t)^2] = \int_{-\infty}^{\infty} P(f) e^{j2\pi 0} df = \int_{-\infty}^{+\infty} P(f) df \tag{3.4}$$

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

$$E[x(t)^2] = \lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^{+T} x(t)^2 dt = \int_{-\infty}^{+\infty} P(f) df \quad (3.5)$$

$P(f)$ Représente donc bien la densité spectrale de puissance du processus $x(t)$. Il s'agit là du théorème de Wiener Khinchine [4].

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

$$p(f) = \int_{-\infty}^{+\infty} \left[\lim_{T \rightarrow +\infty} \frac{1}{2T} \int_{-T}^T x(t)x^*(t-\tau) \right] e^{-j2\pi f\tau} d\tau \quad (3.6)$$

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

$$X_{2T}(f) = \int_{-T}^{+T} x(t)e^{-j2\pi ft} dt \quad (3.7)$$

En prenant le carré de cette expression, il devient :

$$\frac{1}{2T} |X_{2T}(f)|^2 = \frac{1}{2T} \int_{-T-T}^{+T+T} \int_{-T-T}^{+T+T} x(u)x^*(v)e^{-j2\pi fu}e^{+j2\pi fv} dudv \quad (3.8)$$

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

$$E\left[\frac{1}{2T} |X_{2T}(f)|^2\right] = \frac{1}{2T} \int_{-T-T}^{+T+T} \int_{-T-T}^{+T+T} r_{xx}(u-v)e^{-j2\pi f(u-v)} dudv \quad (3.9)$$

En effectuant alors le changement de variable suivant :

$$\begin{cases} \tau = u - v \\ v' = v \end{cases} \quad (3.10)$$

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

Pour : $\tau \geq 0$; v' varie de $-T$ à $+T$, et pour : $\tau \leq 0$; v' varie de T à $-T-\tau$:

$$E\left[\frac{1}{2T} |X_{2T}(f)|^2\right] = \frac{1}{2T} \int_{\tau=0}^{-2T} \int_{v'=-T}^{-T-\tau} r_{xx}(\tau)e^{-j2\pi f\tau} d\tau dv' + \int_{\tau=0}^{-2T} \int_{v'=T}^{-T-\tau} r_{xx}(\tau)e^{-j2\pi f\tau} d\tau dv' \quad (3.11)$$

$$E\left[\frac{1}{2T} |X_{2T}(f)|^2\right] = \frac{1}{2T} \int_{\tau=0}^{-2T} r_{xx}(\tau)(2T-|\tau|)e^{-j2\pi f\tau} d\tau + \int_{\tau=0}^{-2T} r_{xx}(\tau)(-2T+|\tau|)e^{-j2\pi f\tau} d\tau \quad (3.12)$$

D'où finalement :

$$E\left[\frac{1}{2T} |X_{2T}(f)|^2\right] = \int_{\tau=0}^{-2T} r_{xx}(\tau)\left(1 - \frac{|\tau|}{2T}\right)e^{-j2\pi f\tau} d\tau \quad (3.13)$$

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

$$E \left[\frac{1}{2T} |X_{2T}(f)|^2 \right] = TF \left[r_{xx}(\tau) \left(1 - \frac{|\tau|}{2T} \right) I_{4T} \right] \quad (3.14)$$

Nous obtenons donc :

$$E \left[\frac{1}{2T} |X_{2T}(f)|^2 \right] = \left[P(f) * TF \left(1 - \frac{|\tau|}{2T} \right) I_{4T} \right] \quad (3.15)$$

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

$$\text{Lim}_{T \rightarrow \infty} E \left[\frac{1}{2T} |X_{2T}(f)|^2 \right] = [P(f)] \quad (3.16)$$

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 :

$$P_{per}(f) = \frac{1}{NT_e} \left| \sum_{n=0}^{N-1} x(nT_e) e^{-j2\pi n T_e f} \right|^2 \quad (3.17)$$

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, et porte le nom de **corrélogramme**.

$$P_{cor}(f) = \sum_{p=-(N'-1)}^{N'-1} r_{xx}(p) e^{-j2\pi p f} \quad (3.18)$$

Avec :

$$r(p) = \frac{1}{N} \sum_{n=p}^{N-1} x(n)x(n-p)^* \quad (3.19)$$

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

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

$$P_{cor}(f) = \frac{1}{N} \sum_{p=-(N-1)}^{N-1} \sum_{n=p}^{N-1} x(n)x(n-p) * e^{-j2\pi f} \quad (3.20)$$

Expression qui peut encore s'écrire :

$$P_{cor}(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n)e^{-j2\pi f} \right|^2 = P_{per}(f) \quad (3.21)$$

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

3.2.2. 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 :

$$E[P_{cor}(f)] = E \left[\sum_{p=-(N-1)}^{N-1} r_{xx}(p) e^{-j2\pi f} \right] \quad (3.22)$$

Avec :

$$r(p) = \frac{1}{N} \sum_{n=p}^{N-1} x(n)x(n-p) * \quad (3.23)$$

D'où :

$$E[P_{cor}(f)] = \sum_{p=-(N-1)}^{N-1} r_{xx}(p) \frac{N-|p|}{N} e^{-j2\pi f} \quad (3.24)$$

Encore grâce aux propriétés de la Transformée de Fourier :

$$E[P_{cor}(f)] = P(f) * N \left(\frac{\sin \pi f N}{N \sin \pi f} \right)^2 \quad (3.25)$$

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 $N \left(\frac{\sin \pi f N}{N \sin \pi f} \right)^2$.

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

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

$$\text{var}(P_{cor}(f)) = P(f) \left[1 + N \left(\frac{\sin(2\pi f N)}{2\pi f N} \right)^2 \right] \quad (3.26)$$

Cette variance peut être diminuée en séparant l'ensemble des N valeurs de $x(nT_e)$ 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 $\frac{1}{NT_e}$ dans le cas de N échantillons et en $\frac{1}{KT_e}$ dans le cas de K échantillons.

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

En conclusion, le corrélogramme est un estimateur de la densité spectrale de puissance qui est d'autant meilleur que le signal 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.

3.3. Méthodes Paramétriques

Contrairement à l'analyse spectrale "classique", c'est-à-dire liée à la transformée de Fourier (comme le périodogramme ou le corrélogramme), l'analyse spectrale paramétrique est basée sur la connaissance ou l'hypothèse d'un modèle mathématique du signal à analyser.

On cherche alors à estimer les paramètres de ce modèle à partir des échantillons du signal, ce qui donne accès à une connaissance très complète du signal, et en particulier à son

spectre, en remplaçant les paramètres inconnus du modèle par ceux estimés à partir des N échantillons du signal dont on dispose.

Le corrélogramme ou le périodogramme estiment une version biaisée du spectre, directement à partir des échantillons du signal. En revanche, les modélisations paramétriques permettent d'obtenir des estimateurs non biaisés du spectre, pourvus que l'estimation des paramètres soit sans biais.

3.3.1. Modèle AR (Autorégressif)

Les signaux autorégressifs sont obtenus par passage d'un bruit blanc dans un filtre purement récuratif. 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] :

$$x_n = a_1x_{n-1} + a_2x_{n-2} + \dots + a_r x_{n-r} + u_n \tag{3.27}$$

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

$$x_n = a^T X_n + u_n \tag{3.27}$$

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 :

$$H(z) = \frac{1}{1 - \sum_{j=1}^r a_j z^{-j}} \tag{3.28}$$

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 :

$$\begin{aligned} c &= E[x_n X_n] \\ c &= E[(a^T X_n + u_n) X_n] \\ c &= E[a^T X_n] + E[u_n X_n] \end{aligned} \tag{3.29}$$

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

$$c = E[X_n^T X_n] a + E(u_n) E(X_n) \tag{3.30}$$

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

$$C = \Gamma a \tag{3.31}$$

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 premières valeurs de la fonction de corrélation et nous aurons :

$$\sigma_x^2 = E(x^2) = a^T \Gamma a + \sigma_u^2 \tag{3.32}$$

3.3.2. 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 (RIF) [8] [9] [10]. L'équation de récurrence reliant la sortie x_n au signal d'entrée u_n est de la forme :

$$x_n = b_0 u_n + b_1 u_{n-1} + \dots + b_m u_{n-m} \tag{3.33}$$

La fonction de transfert de ce filtre prend la forme :

$$H(z) = \sum_{i=0}^m b_i z^{-i} \tag{3.34}$$

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 :

$$x_{n-k} = b_0 u_{n-k} + b_1 u_{n-k-1} + \dots + b_m u_{n-k-m} \tag{3.35}$$

Nous obtenons alors :

$$E[x_n x_{n-k}] = E[(b_0 u_n + \dots + b_m u_{n-m})(b_0 u_{n-k} + \dots + b_m u_{n-k-m})]. \tag{3.36}$$

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

$$E[u_i u_j] = E(u_i)E(u_j) = 0 \text{ Si } i \neq j \quad E[u_i^2] = \sigma_u^2 \tag{3.37}$$

Nous obtenons :

$$E[x_n x_{n-k}] = \sigma_u^2 (b_0 b_k + b_1 b_{k-1} + \dots + b_{k-m} b_m), \quad |k| < m \quad (3.38)$$

Nous pouvons remarquer d'après l'équation (3.39) que la fonction d'autocorrélation devient nulle à partir d'un décalage k .

Si les quantités $E[x_n x_{n-k}]$ et σ_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.

3.3.3. 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 (**RII**), ces signaux sont une combinaison des signaux **AR** et **MA**. La fonction de transfert du filtre présente un numérateur et un dénominateur [11] [12] :

$$H(z) = \frac{\sum_{i=0}^m b_i z^{-i}}{\sum_{j=0}^r a_j z^{-j}} \quad (3.39)$$

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

$$x(k) = \sum_{i=1}^p a_i x(k-i) + \sum_{i=0}^q b_i e(k-i) \quad (3.40)$$

En multipliant l'équation (3.41) par $x(k-\ell)$ on obtient :

$$x(k)x(k-\ell) = \sum_{i=1}^p a_i x(k-i)x(k-\ell) + \sum_{i=0}^q b_i e(k-i)x(k-\ell) \quad (3.41)$$

En prenant l'espérance mathématique :

$$E[x(k)x(k-\ell)] = E\left[\sum_{i=1}^p a_i x(k-i)x(k-\ell)\right] + \sum_{i=0}^q b_i E[e(k-i)x(k-\ell)] \quad (3.42)$$

$$R_{xx}(\ell) = -\sum_{i=1}^p a_i R_{xx}(\ell-i) + \sum_{i=0}^q b_i R_{ex}(\ell-i) \quad (3.43)$$

d'estimer une somme d'exponentielles par des techniques de prédiction linéaire. C'est avec cette méthode qu'on peut extraire P signaux sinusoïdaux et exponentiels d'une série des données temporelles. Cela est faisable en résolvant des équations linéaires [16] [17]. En effet, on suppose avoir le signal $x(n) = s(n) + b(n)$. Les fonctions $b(n)$ et $s(n)$ sont respectivement un bruit et un signal suppose égal à une somme de sinus amorties de fréquences f_k vérifiant l'équation récursive suivante :

$$s(n) + b_1s(n-1) + \dots + b_{2P}s(n-2P) = 0 \quad (3.47)$$

$$A(z) = z^{2P} + b_1z^{2P-1} + \dots + b_{2P} \quad (3.48)$$

La fonction Polynomiale $A(z)$ a coefficients réels a $2P$ racines complexes conjuguées sur le cercle unité. Ces racines sont données par :

$$z_k = \rho_k e^{\pm 2\pi j f_k} \quad (3.49)$$

Il est possible de calculer b_k , puis les racines z_k ce qui permet de calculer les fréquences f_k et les coefficients d'amortissement ρ_k à partir des racines du polynôme $A(z)$. Si on part de :

$$x(n) + b_1x(n-1) + \dots + b_{2P}x(n-2P) = \epsilon(n) \quad (3.50)$$

Dans ce cas, le problème d'estimation est basé sur la minimisation de l'erreur quadratique ϵ^2 .

En empilant les $(N-2P)$ équations obtenues depuis $(n=2P)$ jusqu'à $(n=N-1)$, on obtient :

$$x(2P) + b_1x(2P-1) + \dots + b_{2P}x(0) = \epsilon(2P) \quad (3.51)$$

$$x(2P+1) + b_1x(2P) + \dots + b_{2P}x(1) = \epsilon(2P+1) \quad (3.52)$$

$$x(N-1) + b_1x(N-2) + \dots + b_{2P}x(N-2P-1) = \epsilon(N-1) \quad (3.53)$$

Cela peut être réécrit en forme matricielle :

$$D \cdot b = e \quad (3.54)$$

D est une matrice $(N-2P) \times (2P+1)$ constituée à partir des données.

$$\mathbf{b} = [1 \ b_1 \ \dots \ b_{2P}]^T \quad (3.55)$$

\mathbf{b} Est donc un vecteur associé aux coefficients de polynôme $A(z)$. Pour estimer \mathbf{b} , la méthode de Prony permet de minimiser le scalaire :

$$e^T e = \mathbf{b}^T \cdot D^T \cdot D \cdot \mathbf{b} \quad (3.56)$$

La contrainte de cette minimisation est avoir la première composante de \mathbf{b} égale à 1.

Si on pose :

$$\mathbf{u} = [1 \ 0 \ \dots \ 0]^T \quad (3.57)$$

$$R = D^T \cdot D \quad (3.58)$$

La matrice R est la covariance de signal $x(n)$. C'est une matrice carrée $(2P + 1) \times (2P + 1)$.

Le problème à résoudre est donc de la forme :

$$\begin{cases} \min(\mathbf{b}^T \cdot R \cdot \mathbf{b}) \\ \mathbf{b}^T \cdot \mathbf{u} - 1 = 0 \end{cases} \quad (3.59)$$

En utilisant la méthode des multiplications de Lagrange, on peut substituer le problème formulé en (3.59) par son équivalent suivant :

$$\begin{cases} \min\{\mathbf{b}^T \cdot R \cdot \mathbf{b} - \lambda(\mathbf{b}^T \cdot \mathbf{u} - 1)\} \\ \mathbf{b}^T \cdot \mathbf{u} - 1 = 0 \end{cases} \quad (3.60)$$

En dérivant la première équation par rapport à \mathbf{b} , on trouve :

$$R \cdot \mathbf{b} = \lambda \cdot \mathbf{u} \quad (3.61)$$

Cela donne :

$$\mathbf{b} = \lambda \cdot R^{-1} \cdot \mathbf{u} \quad (3.62)$$

Si on prend en considération la contrainte indiquée, on écrit :

$$\lambda \cdot u^T \cdot R^{-1} \cdot u - 1 = 0 \quad (3.63)$$

En se basant sur cette dernière équation, on détermine λ . On obtient finalement :

$$b = \frac{1}{u^T \cdot R^{-1} \cdot u} R^{-1} \cdot u \quad (3.64)$$

Théoriquement le polynôme construit à partir des éléments de b à toutes ses racines sur le cercle unité. Pour les obtenir on peut soit calculer directement ses racines, soit évaluer avec la FFT, l'expression $G(f)$ et déterminer ensuite ses maxima. Ceux-ci sont théoriquement en nombre infini.

$$G(f) = \frac{1}{|1 + b_1 e^{-2j\pi f} + \dots + b_{2P} e^{-4Pj\pi f}|} \quad (3.65)$$

3.4.2. Méthode de Pisarenko

La décomposition harmonique de Pisarenko d'un signal $x(n)$, dépend de la décomposition propre de sa matrice de corrélation. Elle permet d'établir un sous-espace de signal et un autre de bruit. Cette procédure est la base des méthodes d'estimation fréquentielle. Elle a une utilité pratique limitée en raison de sa sensibilité au bruit [16] [18] [19]. L'algorithme de cette méthode est résumé comme suit :

- Avec la méthode de covariance, on estime la matrice R_x d'ordre $(2P + 1)$ à partir d'un enregistrement de taille N , comme suit :

$$R_x = \frac{1}{N} \sum_{n=1}^N x(n) \cdot x^H(n) \quad (3.66)$$

- Ensuite, on calcule la décomposition de R_x . On en déduit le vecteur propre v associé à sa plus petite valeur propre.
- On construit avec le vecteur v le polynôme $A(z)$ de degrés $2P$. On extrait ses racines :

$$z_k = e^{2\pi j f_k} \quad (3.67)$$

De cette équation on en déduit les fréquences f_k :

$$f_k = \frac{1}{2\pi} \arg(z_k) \quad (3.68)$$

Le calcul des racines de polynôme $A(z)$ sur le cercle unité, se fait à l'aide de la **FFT** appliquée à ses coefficients sur un grand nombre de points. Puis, on cherche les minimas différents à zéro. Les fréquences se déduisent alors des racines du polynôme prédicteur.

3.4.3. Méthode Burg pour l'estimation des paramètres

La thèse [Burg 1975] a développé une méthode d'estimation des paramètres basée sur les erreurs de prédiction avant et arrière et sur l'estimation directe des coefficients de réflexion.

Un processus autorégressif est un signal stochastique stationnaire (éventuellement complexe) généré par l'équation de différence suivante :

$$x(n) - \mu + \sum_{i=1}^p a_i(x(n-i) - \mu) = \varepsilon(n) \quad (3.69)$$

Où $\varepsilon(n)$ est un signal de bruit blanc. La moyenne du signal est notée. Dans ce processus, les segments sont donnés. Dans chaque segment, le processus est considéré comme stationnaire. L'algorithme de Burg pour les segments peut être dérivé pour des segments de longueur variable. Par souci de simplicité des formules, on supposera que les segments ont la même longueur dans la dérivation donnée ici. L'observation du segment sera notée.

Toutes les propriétés de l'algorithme de Burg pour les segments discutés sont également valables pour des segments de longueur variable. L'algorithme de Burg estime les paramètres **AR** en déterminant des coefficients de réflexion qui minimisent la somme des résidus avant et arrière. L'extension de l'algorithme aux segments est que les coefficients de réflexion sont estimés en minimisant la somme des résidus avant et arrière de tous les segments pris ensemble. Cela signifie qu'un seul modèle est installé sur tous les segments en une fois. Ce concept est également utilisé pour les méthodes d'erreur de prédiction dans l'identification du système, où l'entrée dans le système est connue, comme dans la modélisation **ARX**.

L'avantage de cette approche peut être illustré en examinant deux façons de traiter la moyenne du signal. Avant d'estimer les paramètres **AR** d'un signal avec une moyenne non nulle, la moyenne estimée doit être soustraite. En raison du fait qu'une estimation de la moyenne est soustraite au lieu de la moyenne vraie, cette soustraction introduit un biais dans les paramètres **AR** estimés [20]. Le traitement de la moyenne pour les données non segmentées avec le maximum de vraisemblance peut être trouvé dans [21]. La moyenne peut

être estimée et soustraite pour chaque segment individuellement. Alternativement, une estimation unique de la moyenne peut être obtenue à partir de tous les segments pris ensemble. Comme cette estimation de la moyenne est plus précise, le biais dans les paramètres du modèle provoqué par la soustraction de la moyenne estimée sera réduit. Lorsque les segments sont traités séparément, le biais ne diminue pas lorsque le nombre de segments augmente. Évidemment, l'estimation unique de la moyenne ne devrait être utilisée que lorsque tous les segments sont obtenus à partir de signaux ayant la même moyenne.

Certaines étapes de la dérivation de l'algorithme de Burg seront discutées pour montrer les implications de l'ajustement d'un modèle à tous les segments simultanément. Dans l'algorithme de Burg, les coefficients de réflexion sont estimés directement avec un algorithme récursif [22]. Dans chaque étape de récurrence, un seul coefficient de réflexion est estimé.

Pour estimer le coefficient de réflexion p th, un modèle **AR** est ajusté aux données avec les premiers coefficients de réflexion fixés à la valeur trouvée dans les étapes précédentes. Les paramètres de l'étape sont liés aux paramètres de l'étape précédente par l'algorithme de Levinson-Durbin [22]. Le nouveau coefficient de réflexion est déterminé en minimisant la somme des résidus avant et arrière.

3.4.4. Méthode MUSIC

Cette méthode MUSIC est une version améliorée de l'approche de Pisarenko. Dans celle-ci, l'espace est divisé en sous-espace signal et sous-espace bruit à l'aide de nombreux filtres. La taille de la fenêtre temporelle d'observation est prise de telle sorte qu'elle soit égale à $(C > P + 1)$. Par conséquent, la dimension du sous-espace bruit est supérieur à 1 et égale à $C-P$. Cette méthode permet d'estimer le sous-espace bruit par moyen-âge à partir des échantillons disponibles. Cela donne une meilleure estimation fréquentielle. Il est faisable par décomposition en valeurs propres de la matrice de corrélation estimée ou par décomposition en valeurs singulières de la matrice des données. Une fois la décomposition propre de la matrice de corrélation est calculée, elle est utilisée dans la détermination de la matrice \mathbf{G} de dimensions $(C \times (CP))$. Celle-ci est construite à partir des $(C - P)$ vecteurs propres associés aux $(C - P)$ plus petites valeurs propres. Par la suite, la matrice $\mathbf{G}\mathbf{G}^H$ de dimensions $(C \times C)$ est calculée pour trouver les coefficients de l'équation polynomiale suivante (3.70), [16] [23]:

$$\tilde{Q} = [z^{C-1} \dots z \ 1] G G [1 \ z \dots \ z^{C-1}]^T \quad (3.70)$$

Ensuite, l'estimation des fréquences d'ordre 1 à P , peut être obtenue comme suit :

$$f_k = \frac{\theta_k}{2\pi} \quad (3.71)$$

Deux possibilités sont offertes :

- Calculer les $2(C - 1)$ racines de $\tilde{Q}(z)$ en maintenant stables les P racines, les plus proches du cercle unité. Cette technique s'appelle la méthode Root-MUSIC ;
- Trouver les P minimas, en utilisant la FFT. Cette approche s'appelle la méthode FFT-MUSIC.

3.4.5. Méthode des vecteurs propres EV

Plusieurs méthodes des vecteurs propres ont été proposées pour l'estimation spectrale des exponentielles complexes. Parmi celles-ci, on trouve la méthode des vecteurs propres EV. C'est une technique comparable à l'algorithme MUSIC. La méthode EV permet d'estimer les fréquences exponentielles à partir des sommets de spectre propre suivant [15] [16] [19] :

$$\hat{P}_{EV} = \frac{1}{\sum_{i=P+1}^M \frac{1}{\lambda_i} |e(f)v_i^H|^2} \quad (3.72)$$

Où les 2_i sont les valeurs propres associées aux vecteurs propres v_i . e Est le vecteur de direction. Il contient les fréquences recherchées. La seule différence entre l'approche MUSIC et celle EV est l'utilisation des valeurs propres inverses. Les λ_i sont aussi les valeurs propres de la matrice d'autocorrélation R_x . En plus de sa compensation à la distorsion, ce procédé EV produit moins de pics parasites que la méthode MUSIC.

3.4.6. Méthode de norme minimale MN

Cette méthode est celle de décomposition propre. C'est un algorithme de norme minimale MN. Dans cette approche, on utilise un seul vecteur a pour l'estimation fréquentielle. On n'a pas besoin de former un spectre propre utilisant tous les vecteurs propres. Cette méthode est donc basée sur la projection du vecteur du signal e_k sur l'ensemble de sous-espace bruit [24]

:

$$e_k = [1 \ e^{j2\pi f_k} \ \dots \ e^{j(N-1)2\pi f_k}]^T \quad (3.73)$$

Les fréquences des exponentielles complexes sont estimées à partir des pics du spectre fréquentiel, donne par l'équation suivante :

$$\hat{P}_{MN}(e^{j2\pi f_k}) = \frac{1}{|e^H \alpha|^2}; \alpha = \lambda P_n u_1 \quad (3.74)$$

Où P_n est une matrice obtenue par projection de e_k sur le sous-espace bruit. Les X sont les valeurs propres de la matrice d'autocorrélation du signal.

Si la séquence d'autocorrélation est connue de façon précise, alors $|e^H \alpha|^2$ aura des valeurs nulles α des fréquences de chaque exponentielle complexe. Par conséquent, la transformée en z des coefficients qui se trouvent dans α peut-être factorisée en tant que :

$$A(z) = \sum_{k=0}^{N-1} \alpha_k z^{-k} = \prod_{k=1}^p (1 - e^{j2\pi f_k} z^{-1}) \prod_{k=p+1}^{N-1} (1 - z_k z^{-1}) \quad (3.75)$$

Pour $k = p + 1, \dots, N - 1$. Les z_k sont les racines parasites existantes hors du cercle unite.

Le problème est de déterminer le vecteur de sous-espace bruit permettant de réduire au minimum les effets des zéros parasites sur les sommets de \hat{P}_{MN} . L'algorithme de norme minimale consiste donc à trouver un vecteur α vérifiant les trois contraintes suivantes :

1. α est un vecteur appartenant au sous-espace bruit;
2. α est un vecteur ayant une norme euclidienne minimale;
3. α est un vecteur ayant 1 comme première composante.

La première contrainte assure que les p racines de $A(z)$ sont situées sur le cercle unité. Tandis que la deuxième contrainte garantit l'emplacement des racines parasites de $A(z)$ à l'intérieur du cercle unité :

$$|z_k| < 1 \quad (3.76)$$

La troisième contrainte peut être exprimée comme suit :

$$\alpha^H u_1 = 1 \quad (3.77)$$

$$u_1 = [1, 0, \dots, 0]^T \quad (3.78)$$

3.5. Les résultats de simulations

Les résultats présentés ci-dessous sont obtenus en appliquant les techniques d'analyse spectrale que nous venons de présenter sur le modèle de système de production d'énergie obtenu et validé dans le chapitre II. Les figures ci-dessous montrent les performances de l'analyse spectrale pour la détection des défauts. Notre étude de simulation est basée sur la variation du défaut de backlash de 0.1 rad jusqu'à 0.4 rad au niveau de multiplicateur de vitesse (gearbox) et visualiser l'influence sur les différentes réponses du système complet (le couple électromagnétique, la vitesse de la turbine, la puissance produite, ...). Cette étude en analyse spectrale est réalisée sur les deux approches évoquées précédemment. En ce qui concerne les méthodes non paramétriques, nous sélectionnons le Périodogramme et le Spectrogramme. Cependant pour les méthodes paramétriques, nous avons choisi la méthode de prony et la méthode Burg.

3.5.1. Etude en simulation par les méthodes non paramétriques :

L'analyse fréquentielle permet de visualiser la pollution fréquentielle indicatrice d'une présence de défaut. Pour ce faire, nous avons utilisé la méthode du Périodogramme et la méthode du spectrogramme. Les résultats de simulation obtenus sont illustrés sur les figures ci-dessous.

3.5.1.1. Méthode de périodogramme :

Cas_01 : Périodogramme avec un défaut de Backlash de l'ordre de $J_0=0.1$ rad :

Les figures (**Fig.3.2**) jusqu'à (**Fig.3.7**) montrent le périodogramme de : couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide, coefficient de puissance, le couple mécanique et la puissance mécanique pour un défaut de Backlash $J_0=0.1$ rad.

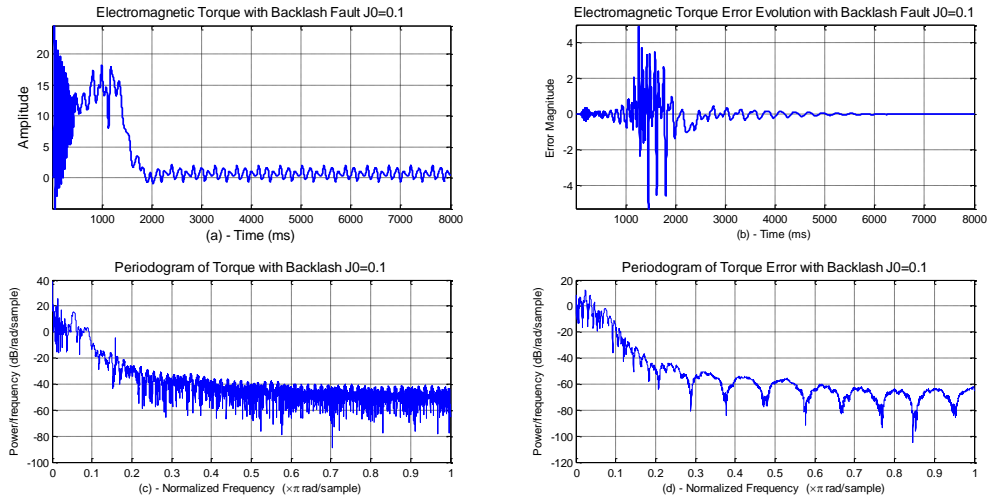


Fig.3.2- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétiques (C_e), (b)-Erreur sur C_e , (c)-Périodogramme(C_e) et (d)- Périodogramme(Err_{C_e}).

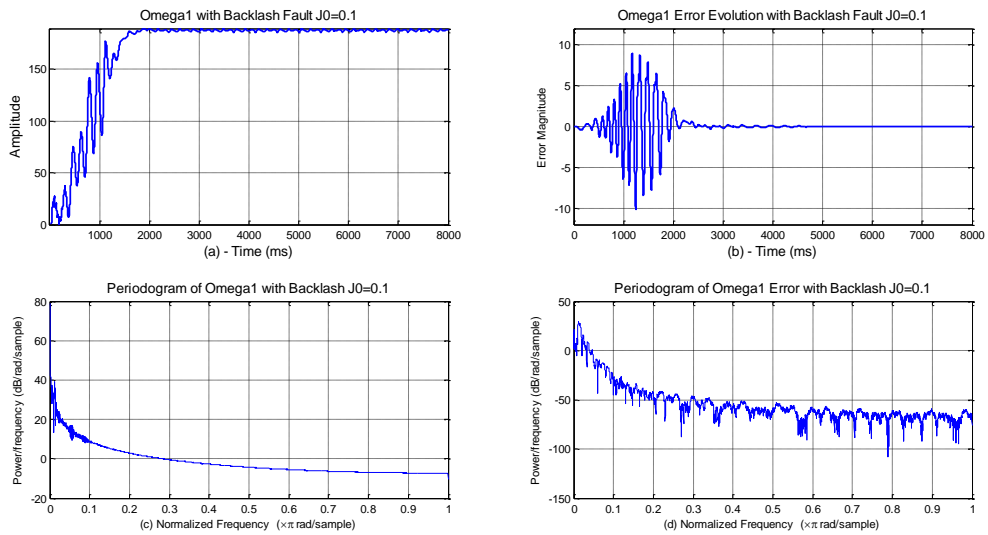


Fig.3.3- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente Ω_1 , (b)-Erreur sur Ω_1 , (c)-Périodogramme (Ω_1) et (d)- Périodogramme (Err_{Ω_1}).

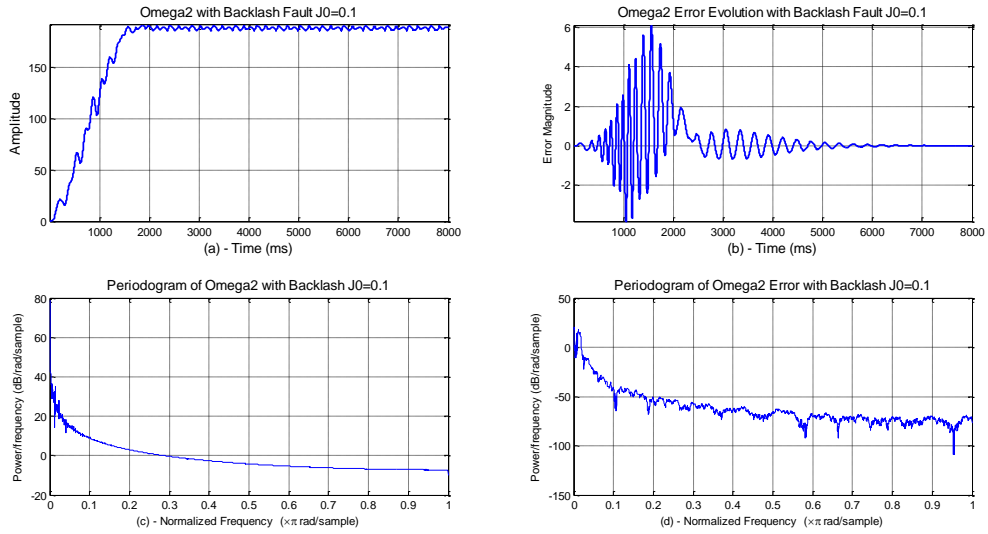


Fig.3.4- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide (Ω_2), (b)-Erreur sur Ω_2 , (c)-Périodogramme (Ω_2) et (d)- Périodogramme (Err_{Ω_2}).




Fig.3.5- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance (C_p), (b)-Erreur sur C_p , (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_{C_p}).

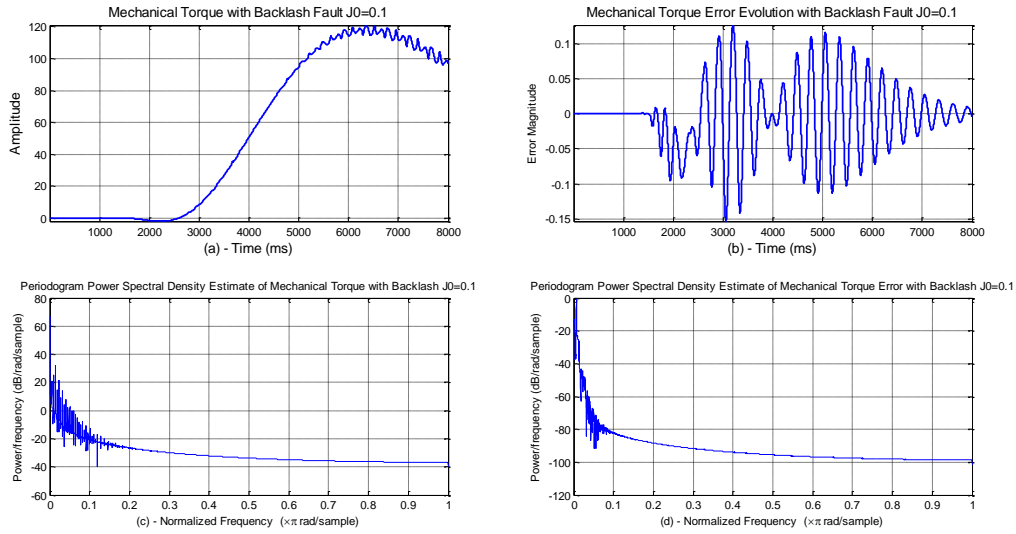


Fig.3.6- Evolution temporelle et fréquentielle du : (a)-Couple mécanique T_m , (b)-Erreur sur T_m , (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_{T_m}).

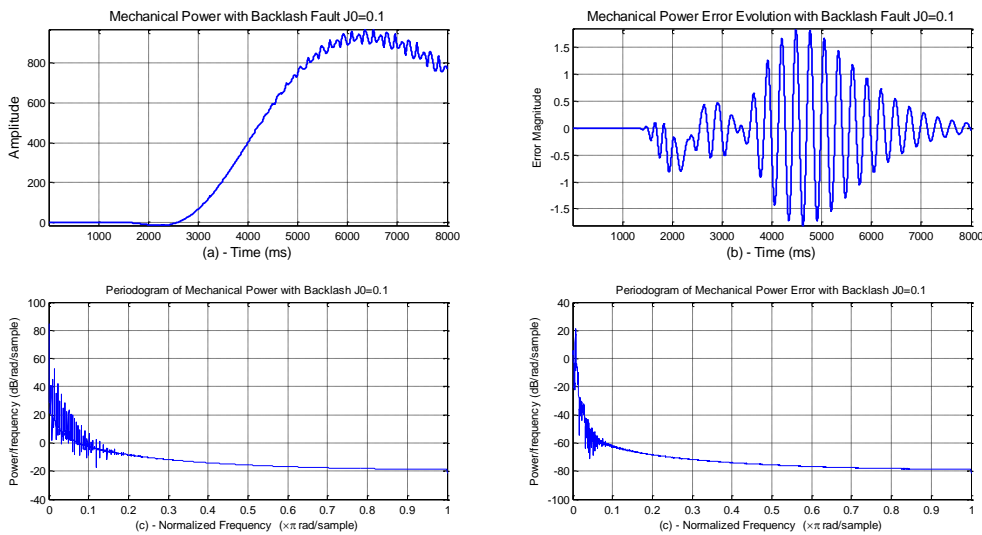


Fig.3.7- Evolution temporelle et fréquentielle du : (a)-Puissance mécanique P_m , (b)-Erreur sur P_m , (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_{P_m}).

Cas_02 : Périodogramme avec un défaut de Backlash de l'ordre de $J_0=0.2$ rad :

Les figures (Fig.3.8) jusqu'à (Fig.3.13) illustrent le périodogramme des différentes grandeurs mesurées avec un défaut de backlash d'amplitude $J_0=0.2$ rad. Comparativement avec $J_0=0.1$ rad, nous pouvons remarquer clairement les fluctuations au niveau de l'évolution temporelle et fréquentielle observées sur les grandeurs C_e , Ω_1 , Ω_2 , C_p , T_m et P_m .

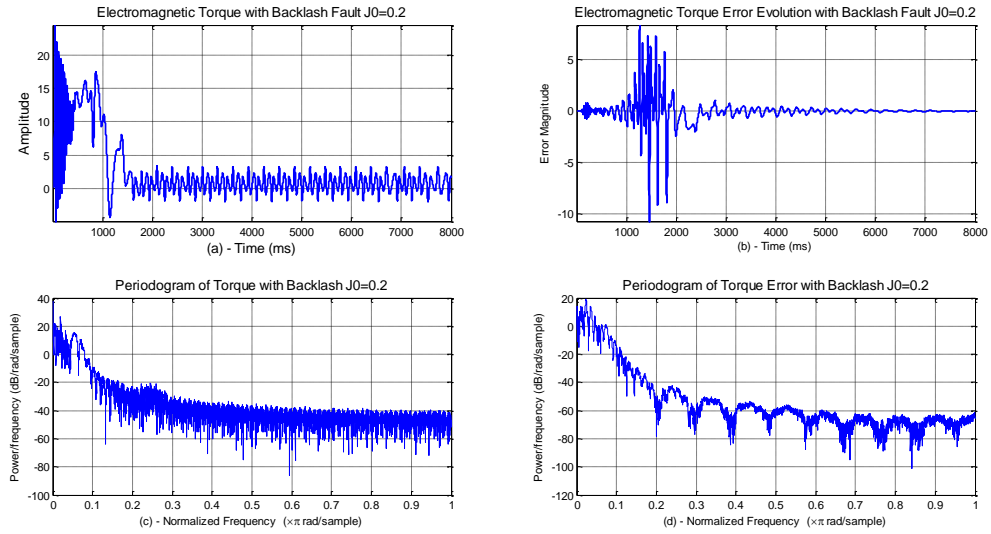


Fig.3.8- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétiques (C_e), (b)-Erreur sur C_e , (c)-Périodogramme(C_e) et (d)- Périodogramme(Err_C_e).

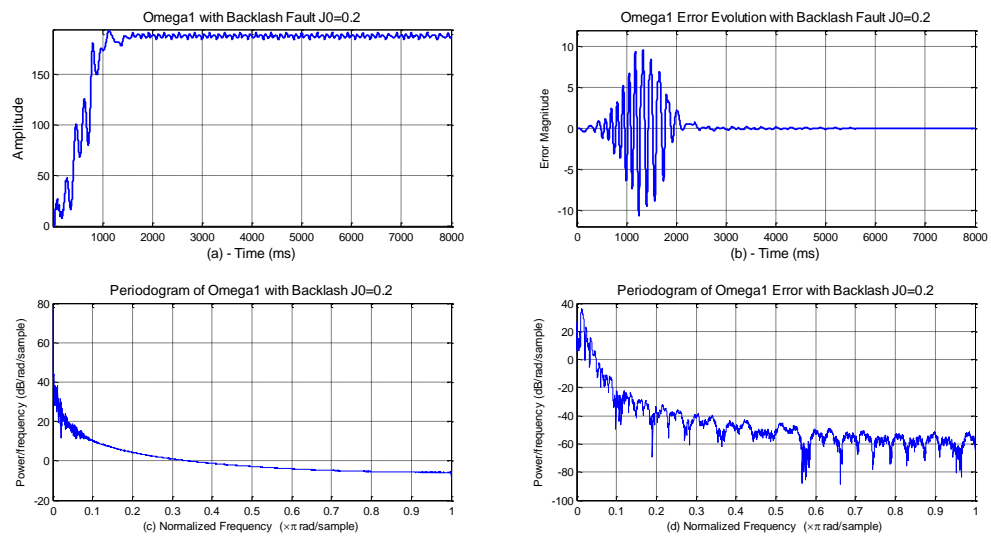


Fig.3.9- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente (Ω_1), (b)-Erreur sur Ω_1 , (c)-Périodogramme (Ω_1) et (d)- Périodogramme ($Err_ \Omega_1$).

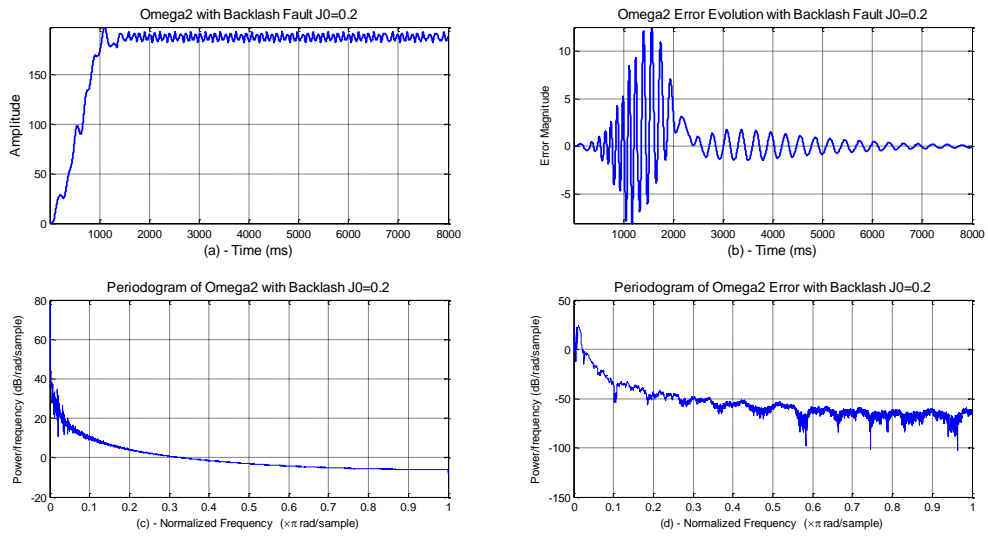


Fig.3.10- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide (Ω_2), (b)-Erreur sur Ω_2 , (c)-Périodogramme (Ω_2) et (d)- Périodogramme (Err_{Ω_2}).

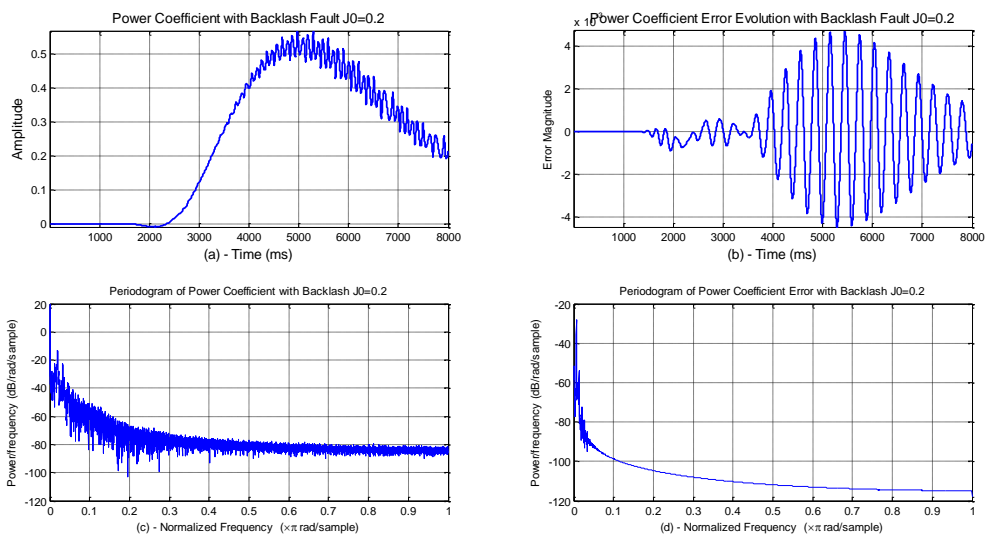


Fig.3.11- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance (C_p), (b)-Erreur sur C_p , (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_{C_p}).




Fig.3.12- Evolution temporelle et fréquentielle du : (a)-Couple mécanique T_m , (b)- Erreur sur T_m , (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_{T_m}).

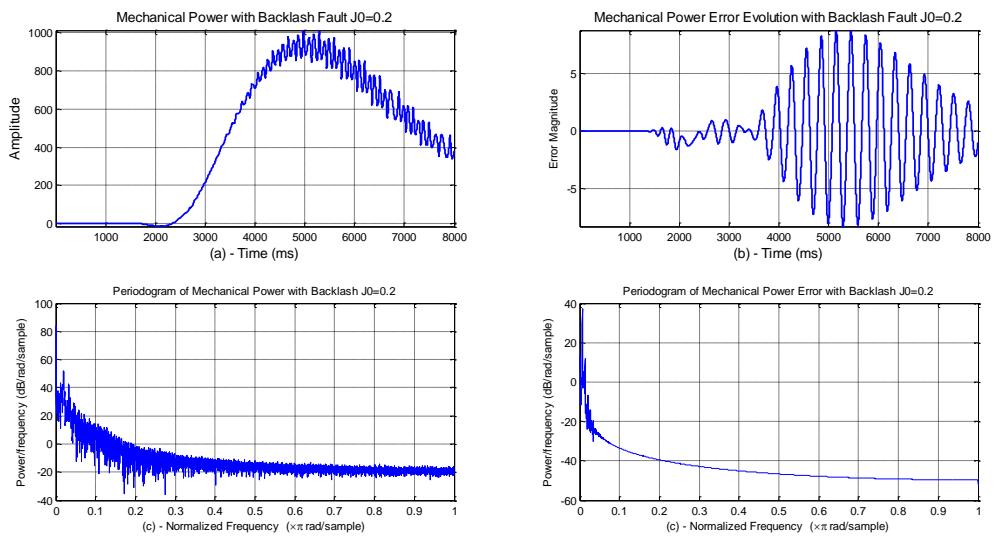


Fig.3.13- Evolution temporelle et fréquentielle du : (a)-Puissance mécanique P_m , (b)- Erreur sur P_m , (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_{P_m}).

Cas_03 : Périodogramme avec un défaut de Backlash de l'ordre de $J_0=0.3$ rad :

Les figures (Fig.3.14 à Fig.3.19) présentent l'évolution du périodogramme appliqué sur les différentes grandeurs. D'après les résultats de simulation, nous pouvons dire que plus l'amplitude du défaut de backlash augmente, les fluctuations harmoniques deviennent de plus en plus importantes.

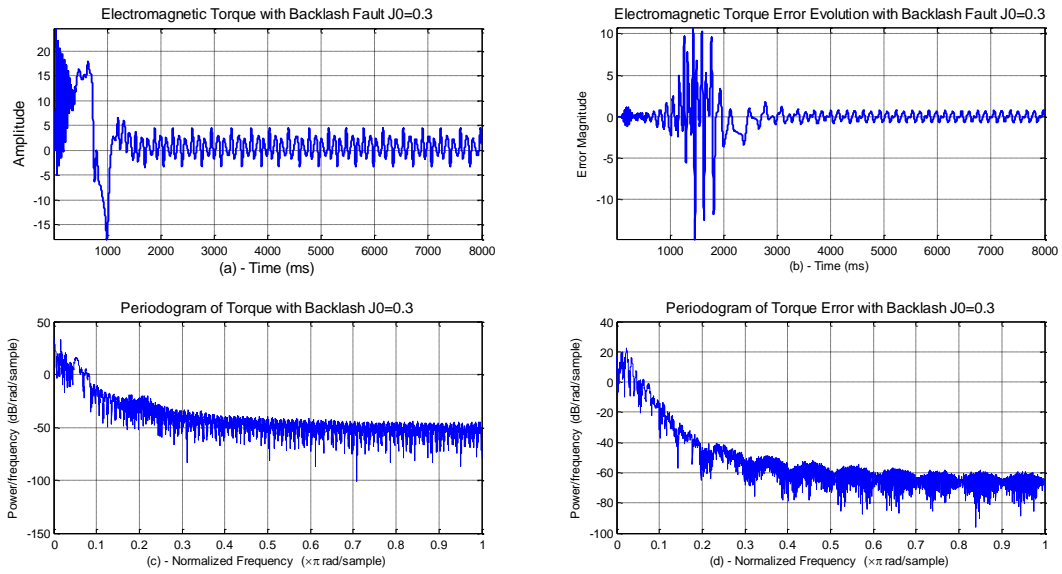


Fig.3.14- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétique C_e , (b)-Erreur sur C_e , (c)-Périodogramme (C_e) et (d)- Périodogramme (Err_{C_e}).

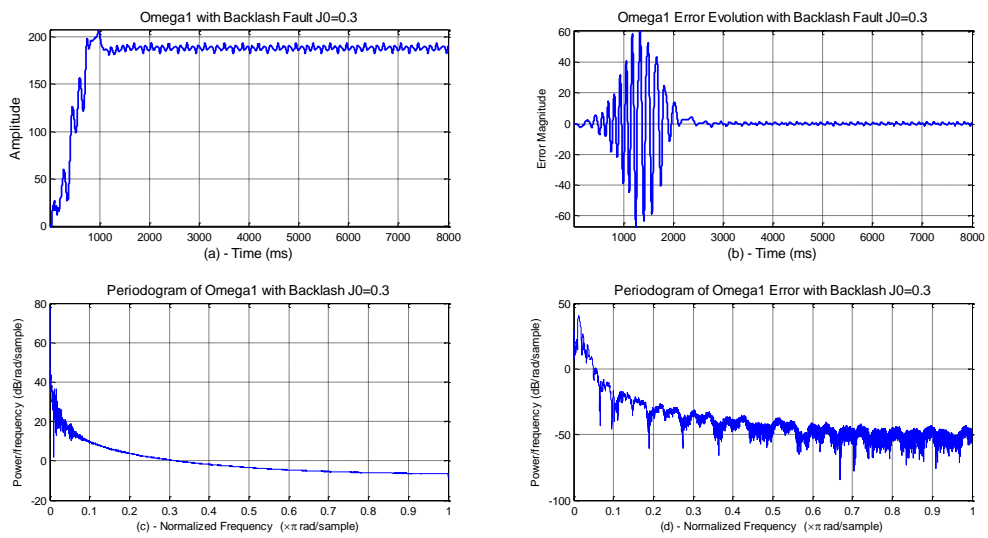


Fig.3.15- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente Ω_1 , (b)-Erreur sur Ω_1 , (c)-Périodogramme (Ω_1) et (d)- Périodogramme (Err_{Ω_1}).

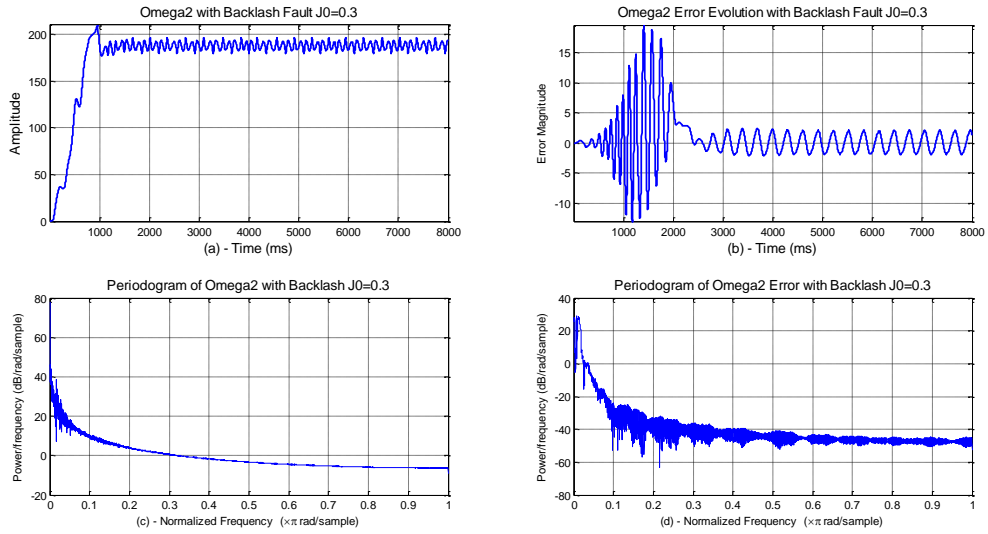


Fig.3.16- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide Ω_2 , (b)-Erreur sur Ω_2 , (c)-Périodogramme (Ω_2) et (d)- Périodogramme (Err_{Ω_2}).

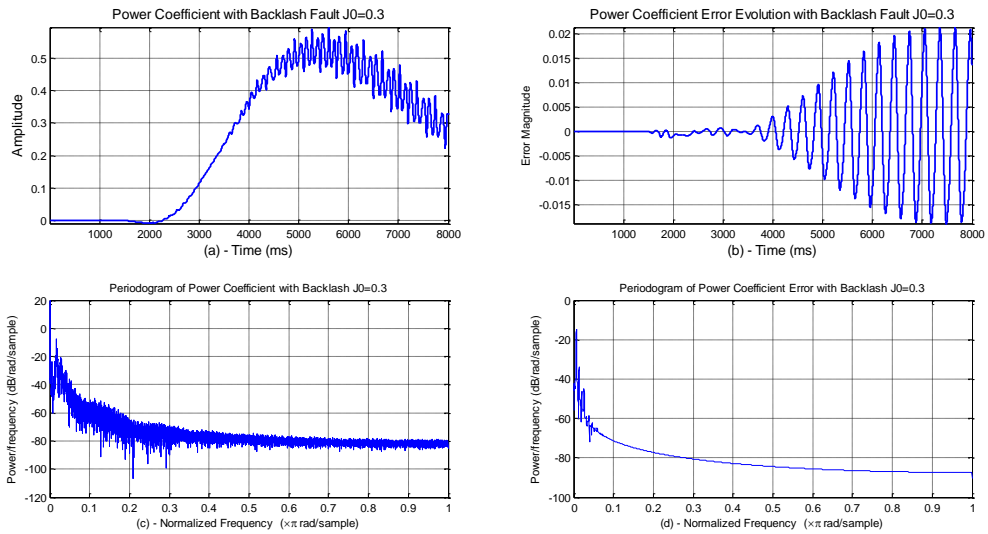


Fig.3.17- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance C_p , (b)- Erreur sur C_p , (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_{C_p}).




Fig.3.18- Evolution temporelle et fréquentielle du : (a)-Couple Mécanique T_m , (b)- Erreur sur T_m , (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_{T_m}).

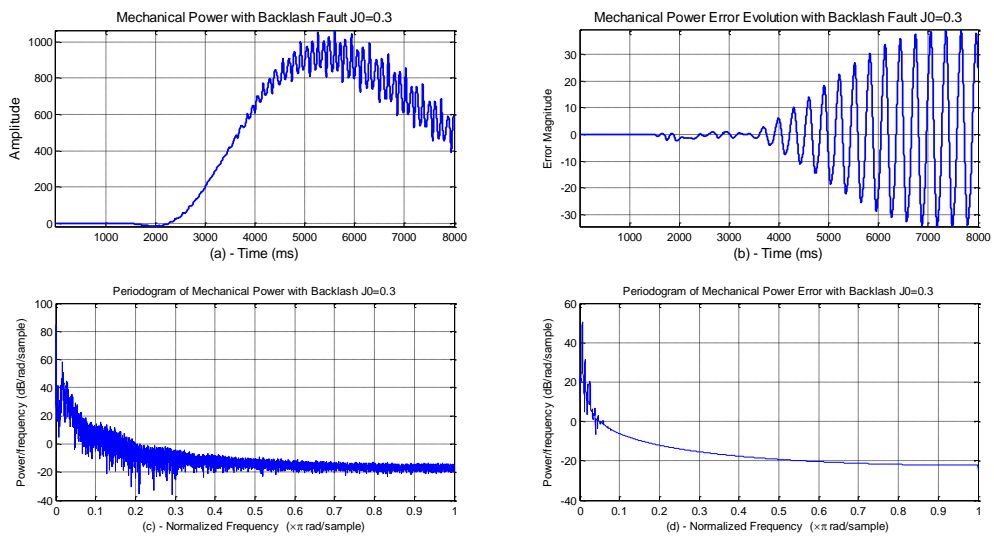


Fig.3.19- Evolution temporelle et fréquentielle du : (a)-Puissance Mécanique P_m , (b)- Erreur sur P_m , (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_{P_m}).

Cas_04 : Périodogramme avec un défaut de Backlash de l'ordre de $J_0=0.4$ rad :

Les figures (Fig.3.20 à Fig.3.25) montrent la sensibilité des différentes grandeurs (C_e , Ω_1 , Ω_2 , C_p , T_m et P_m) vis-à-vis la variation de l'amplitude du défaut de backlash. Les mêmes constations restent valables pour ce scénario de simulation.

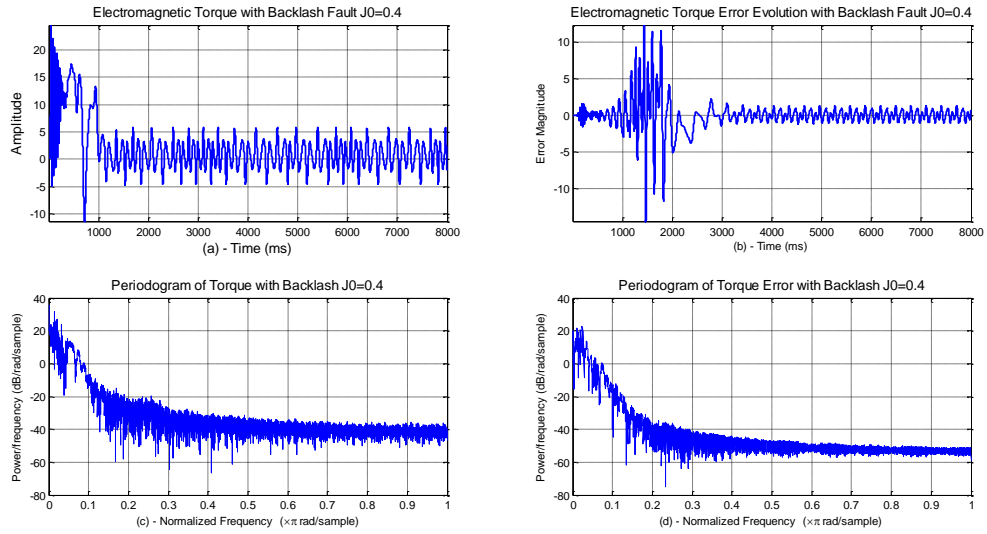


Fig.3.20- Evolution temporelle et fréquentielle du : (a)-Couple électromagnétique C_e , (b)-Erreur sur C_e , (c)-Périodogramme (C_e) et (d)- Périodogramme (Err_{C_e}).

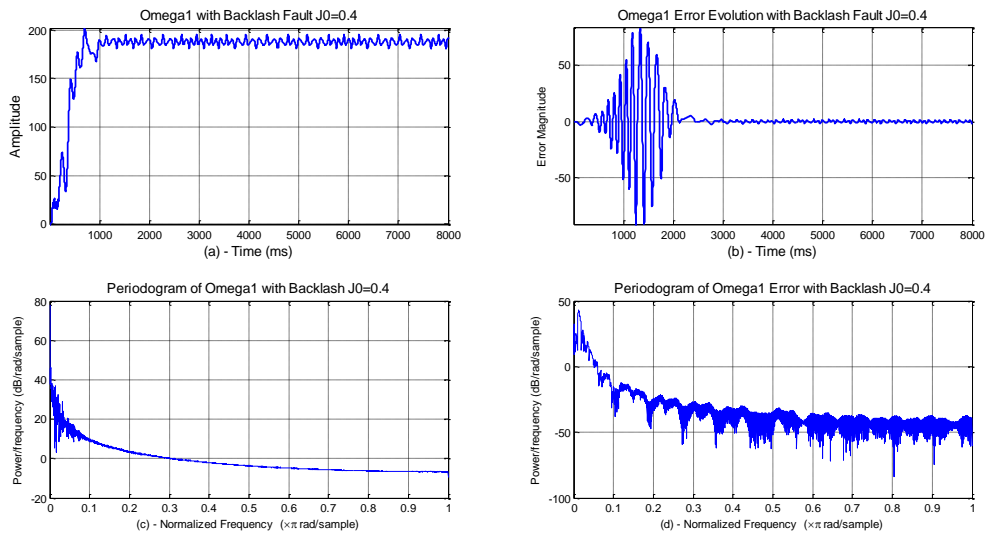


Fig.3.21- Evolution temporelle et fréquentielle du : (a)-Vitesse Lente Ω_1 , (b)-Erreur sur Ω_1 , (c)-Périodogramme (Ω_1) et (d)- Périodogramme (Err_{Ω_1}).

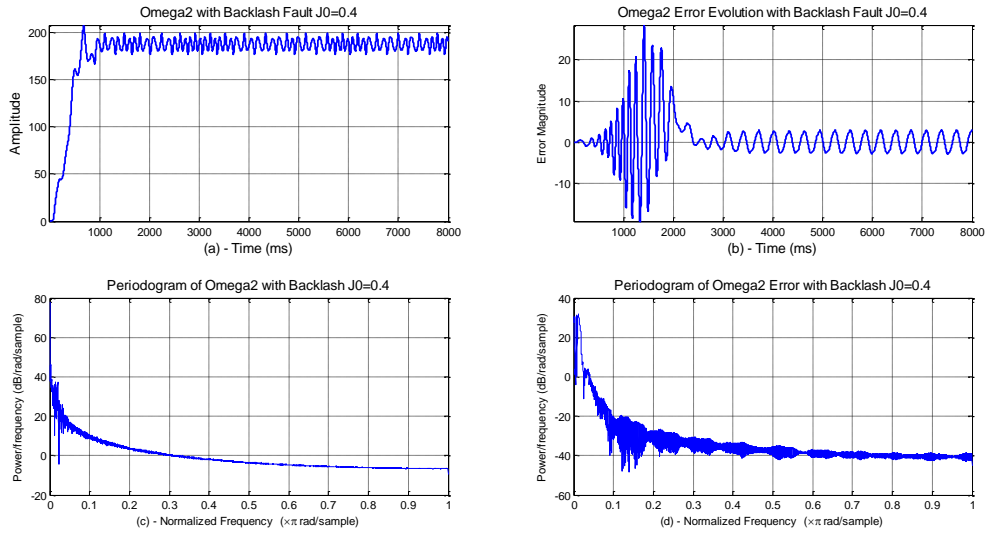


Fig.3.22- Evolution temporelle et fréquentielle du : (a)-Vitesse Rapide Ω_2 , (b)-Erreur sur Ω_2 , (c)-Périodogramme (Ω_2) et (d)- Périodogramme (Err_{Ω_2}).

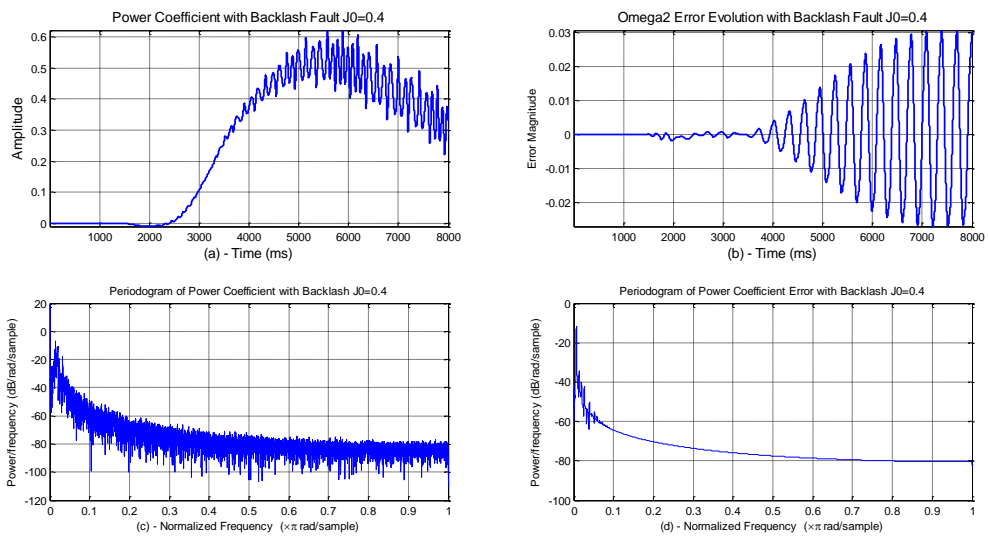


Fig.3.23- Evolution temporelle et fréquentielle du : (a)-Coefficient de puissance C_p , (b)- Erreur sur C_p , (c)-Périodogramme (C_p) et (d)- Périodogramme (Err_{C_p}).

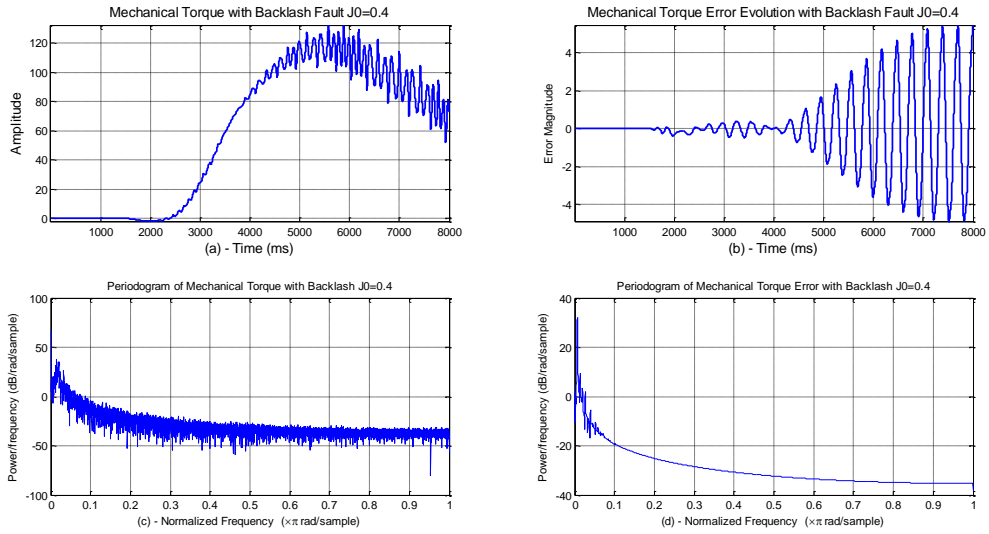


Fig.3.24- Evolution temporelle et fréquentielle du : (a)-Couple Mécanique T_m , (b)- Erreur sur T_m , (c)-Périodogramme (T_m) et (d)- Périodogramme (Err_T_m).

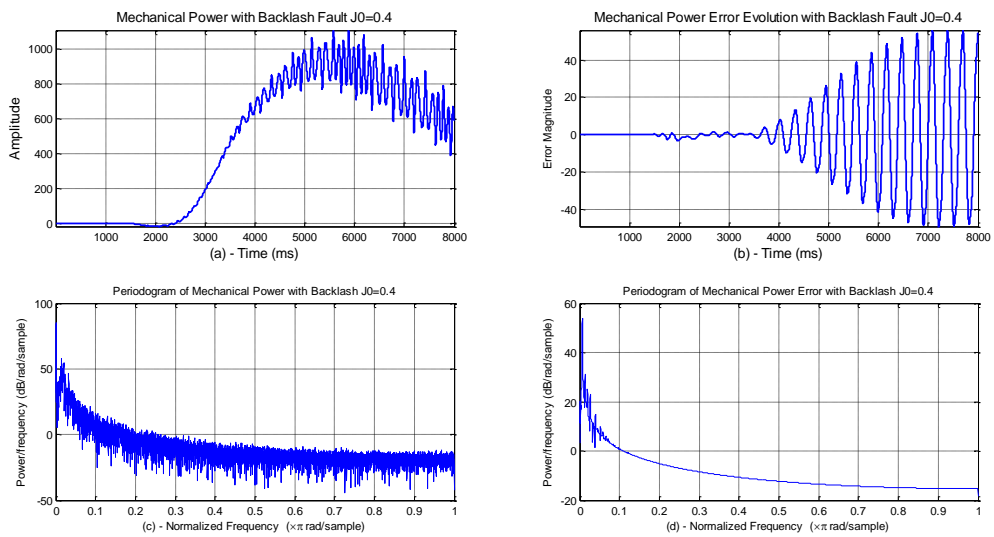


Fig.3.25- Evolution temporelle et fréquentielle du : (a)-Puissance Mécanique P_m , (b)- Erreur sur P_m , (c)-Périodogramme (P_m) et (d)- Périodogramme (Err_P_m).

Discussion des résultats :

Les résultats de simulation illustrés ci-dessus présentent le comportement du périodogramme vis-à-vis les niveaux d'amplitudes du défaut de backlash. Pour valider l'influence de ce phénomène d'altération mécanique, nous avons mesuré les grandeurs suivantes : les grandeurs $C_e, \Omega_1, \Omega_2, C_p, T_m$ et P_m . L'analyse des différentes réponses temporelle et fréquentielles montre l'influence de ce défaut sur le bon fonctionnement de l'éolienne. Les figures (Fig.3.2 à Fig.3.25) montrent clairement que le spectre obtenu par le

périodogramme présente de nombreuses discontinuités et il délivre une bonne résolution spectrale. Les fluctuations qui apparaissent au niveau des différentes réponses se manifestent sous forme d'harmoniques parasites au niveau de la tension injectée au réseau électrique.

3.5.1.2. Méthode de Spectrogramme :

Cas_01- Spectrogramme avec un défaut de Backlash $J_0=0.1$ rad :

Les figures (Fig.3.26 à Fig.3.31) montrent : (a) l'évolution du signal temporel, (b) l'évolution de l'erreur du signal temporel, (c) Représentation temps-fréquence obtenue avec le spectrogramme et (d) la Densité Spectrale de Puissance (DSP) calculée à partir de l'erreur sur les grandeurs $C_e, \Omega_1, \Omega_2, C_p, T_m$ et P_m pour un défaut de backlash $J_0=0.1$ rad.

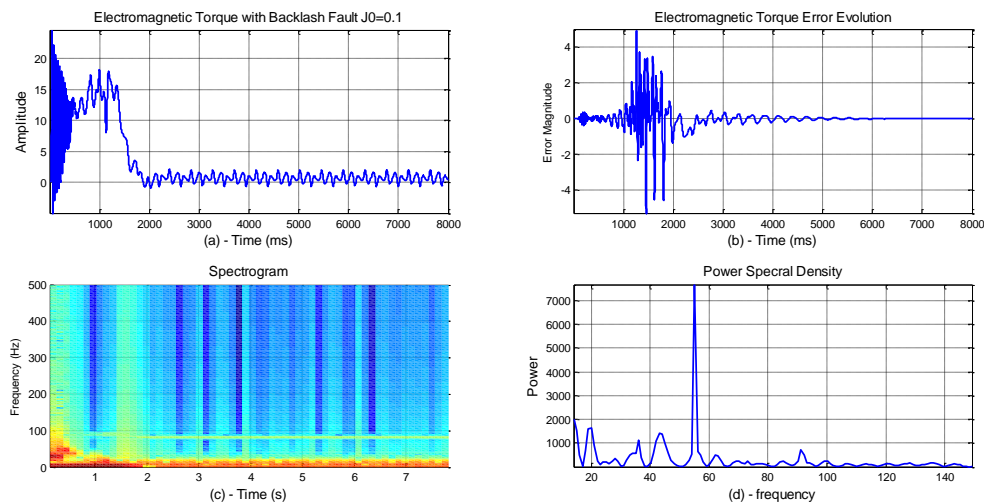


Fig.3.26- (a)- Evolution temporelle de C_e , (b)-Erreur sur C_e , (c)- Spectrogramme de (Err_{C_e}) et DSP de (Err_{C_e}) pour un défaut de backlash $J_0=0.1$ rad.

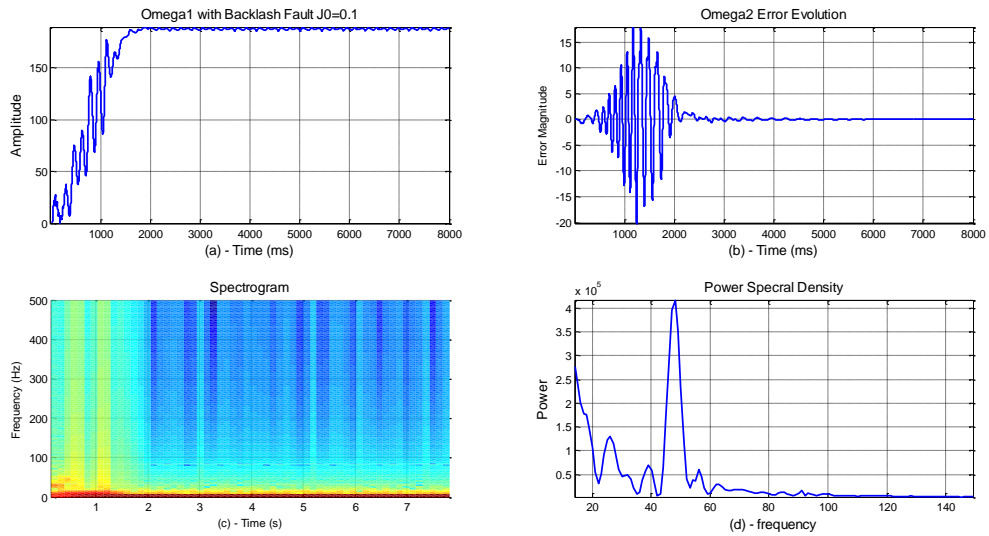


Fig.3.27- (a)- Evolution temporelle de Ω_1 , (b)-Erreur sur Ω_1 , (c)- Spectrogramme de $(Err_ \Omega_1)$ et DSP de $(Err_ \Omega_1)$ pour un défaut de backlash $J_0=0.1$ rad.

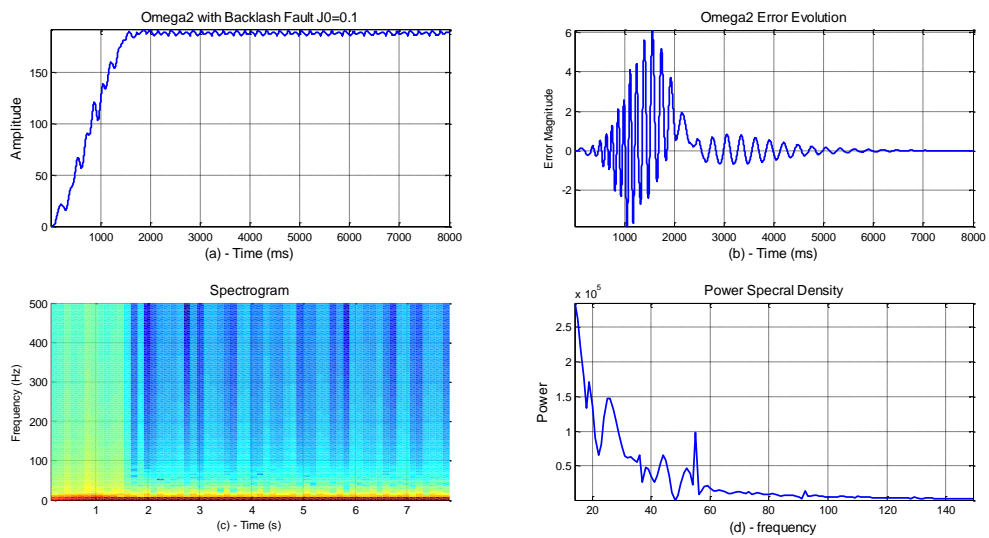


Fig.3.28- (a)- Evolution temporelle de Ω_2 , (b)-Erreur sur Ω_2 , (c)- Spectrogramme de $(Err_ \Omega_2)$ et DSP de $(Err_ \Omega_2)$ pour un défaut de backlash $J_0=0.1$ rad.

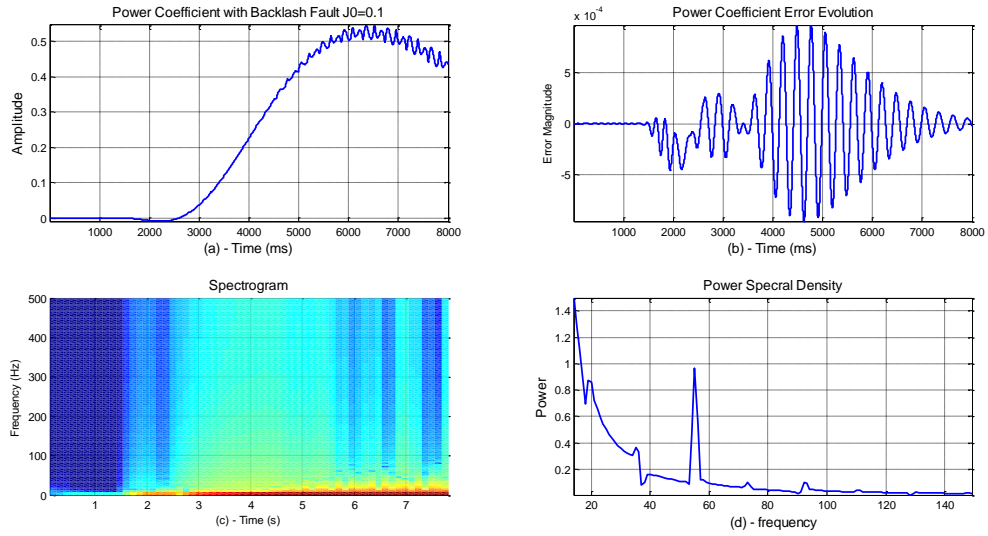


Fig.3.29- (a)- Evolution temporelle du C_p , (b)-Erreur sur C_p , (c)- Spectrogramme de (Err_C_p) et DSP de (Err_C_p) pour un défaut de backlash $J_0=0.1$ rad.

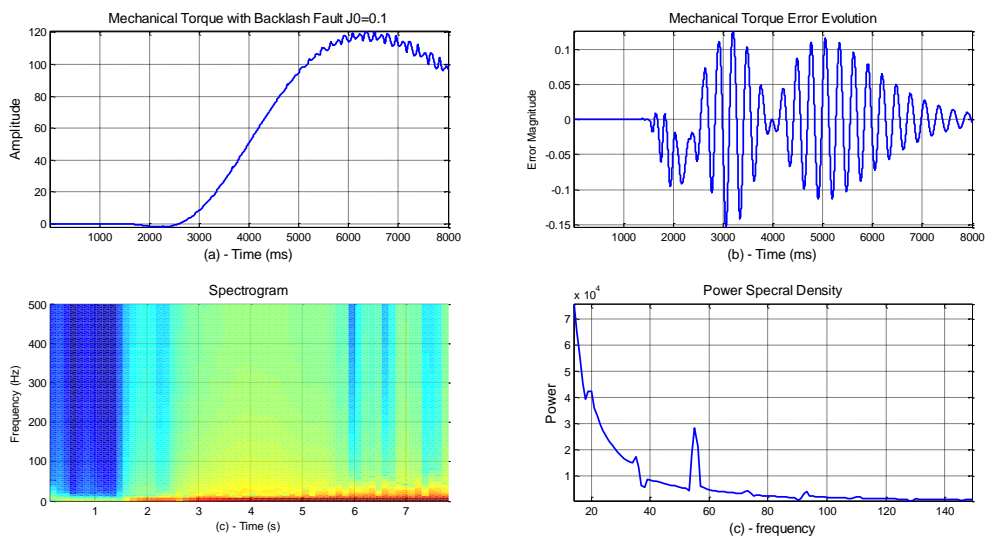


Fig.3.30- (a)- Evolution temporelle du T_m , (b)-Erreur sur T_m , (c)- Spectrogramme de (Err_T_m) et DSP de (Err_T_m) pour un défaut de backlash $J_0=0.1$ rad.

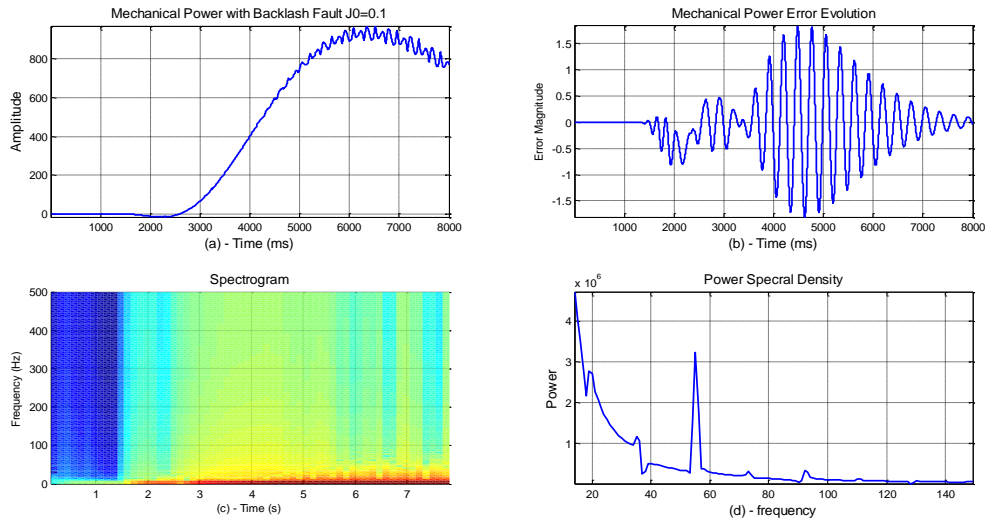


Fig.3.31- (a)- Evolution temporelle du P_m , (b)-Erreur sur P_m , (c)- Spectrogramme de (Err_P_m) et DSP de (Err_P_m) pour un défaut de backlash $J_0=0.1$ rad.

Cas_02 Spectrogramme pour un défaut de Backlash $J_0=0.2$ rad :

Les figures (Fig.3.32 à Fig.3.37) montrent : (a) l'évolution du signal temporel, (b) l'évolution de l'erreur du signal temporel, (c) Représentation temps-fréquence obtenue avec le spectrogramme et (d) la Densité Spectrale de Puissance (DSP) calculée à partir de l'erreur sur les grandeurs C_e , Ω_1 , Ω_2 , C_p , T_m et P_m pour un défaut de backlash de l'ordre de $J_0=0.2$ rad. A travers ces figures, nous pouvons voir clairement qu'il y a un changement de comportement fréquentielle au niveau de la DSP et le spectrogramme. Ce changement se manifeste au niveau de la composante principale et les composantes secondaires.

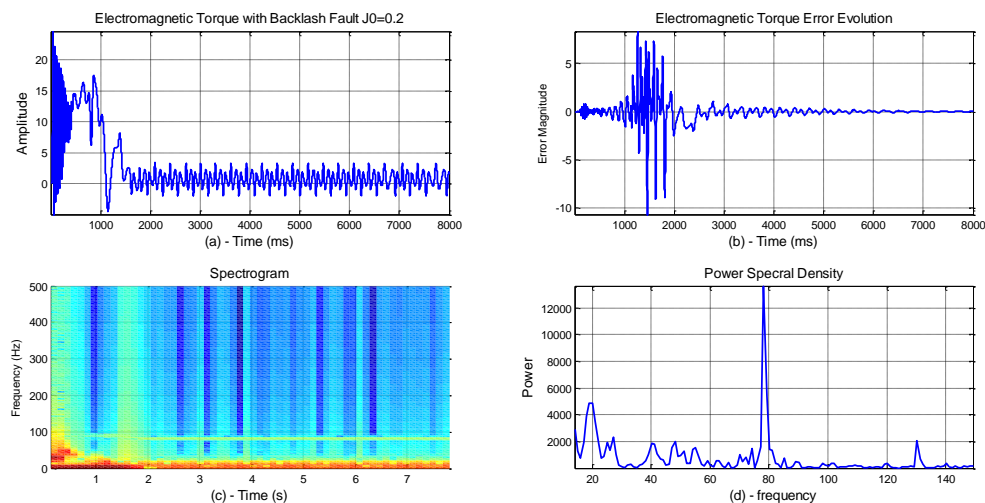


Fig.3.32- (a)- Evolution temporelle de C_e , (b)-Erreur sur C_e , (c)- Spectrogramme de (Err_C_e) et DSP de (Err_C_e) pour un défaut de backlash $J_0=0.2$ rad.

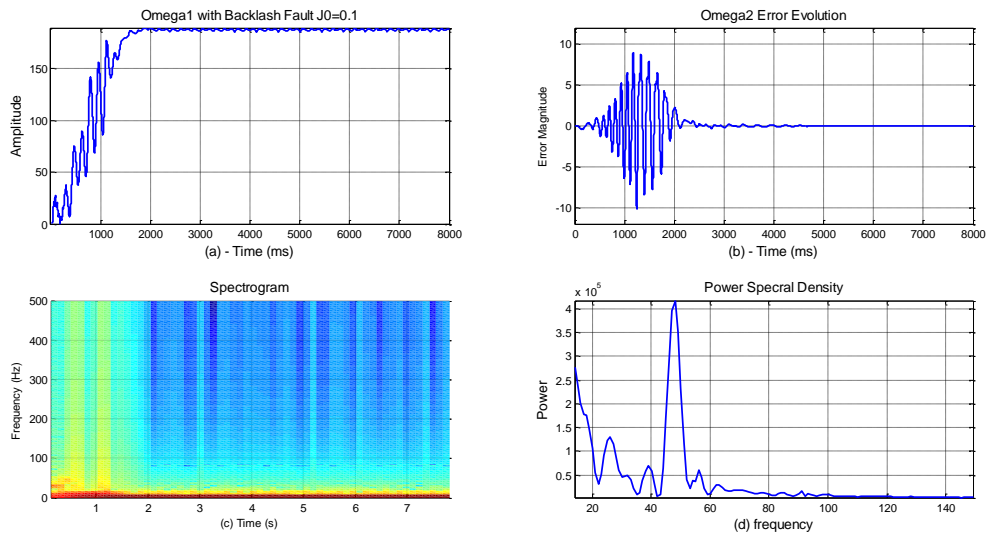


Fig.3.33- (a)- Evolution temporelle de Ω_1 , (b)-Erreur sur Ω_1 , (c)- Spectrogramme de $(Err_ \Omega_1)$ et DSP de $(Err_ \Omega_1)$ pour un défaut de backlash $J_0=0.2$ rad.

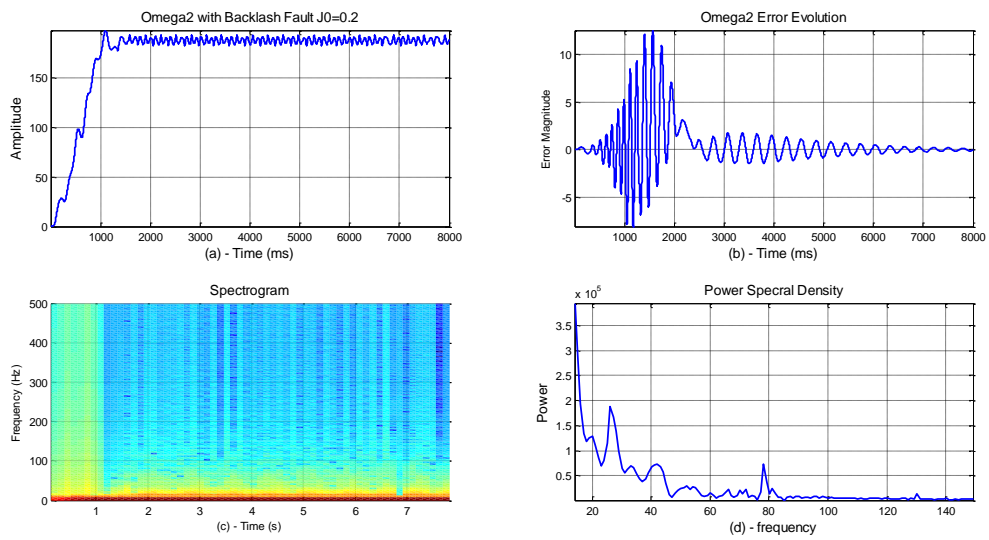


Fig.3.34- (a)- Evolution temporelle de Ω_2 , (b)-Erreur sur Ω_2 , (c)- Spectrogramme de $(Err_ \Omega_2)$ et DSP de $(Err_ \Omega_2)$ pour un défaut de backlash $J_0=0.2$ rad.

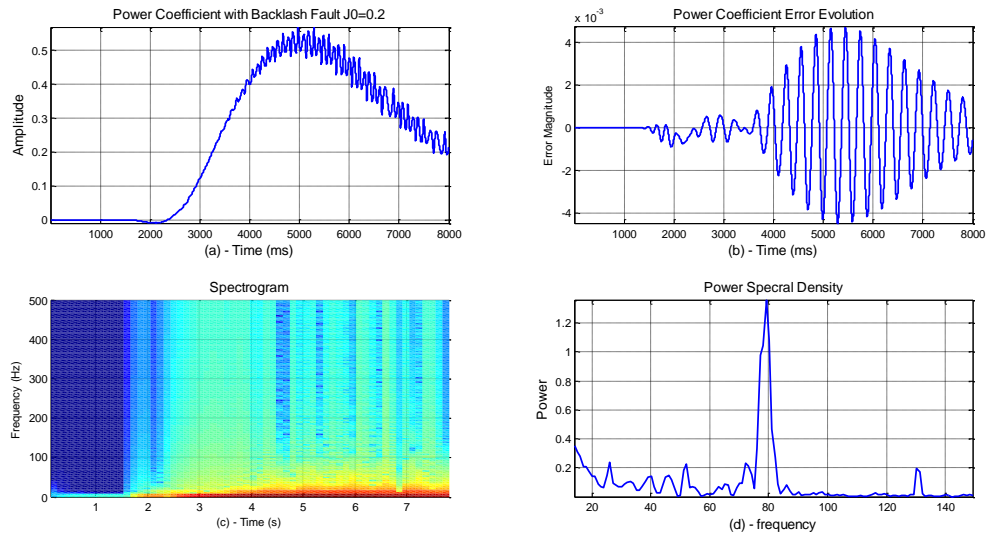


Fig.3.35- (a)- Evolution temporelle du C_p , (b)-Erreur sur C_p , (c)- Spectrogramme de (Err_C_p) et DSP de (Err_C_p) pour un défaut de backlash $J_0=0.2$ rad.

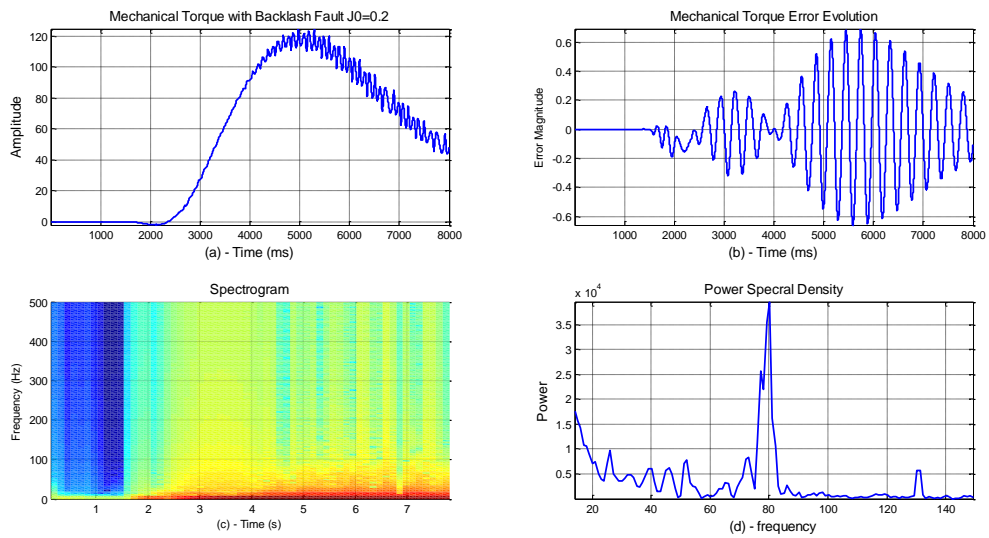


Fig.3.36- (a)- Evolution temporelle du T_m , (b)-Erreur sur T_m , (c)- Spectrogramme de (Err_T_m) et DSP de (Err_T_m) pour un défaut de backlash $J_0=0.2$ rad.

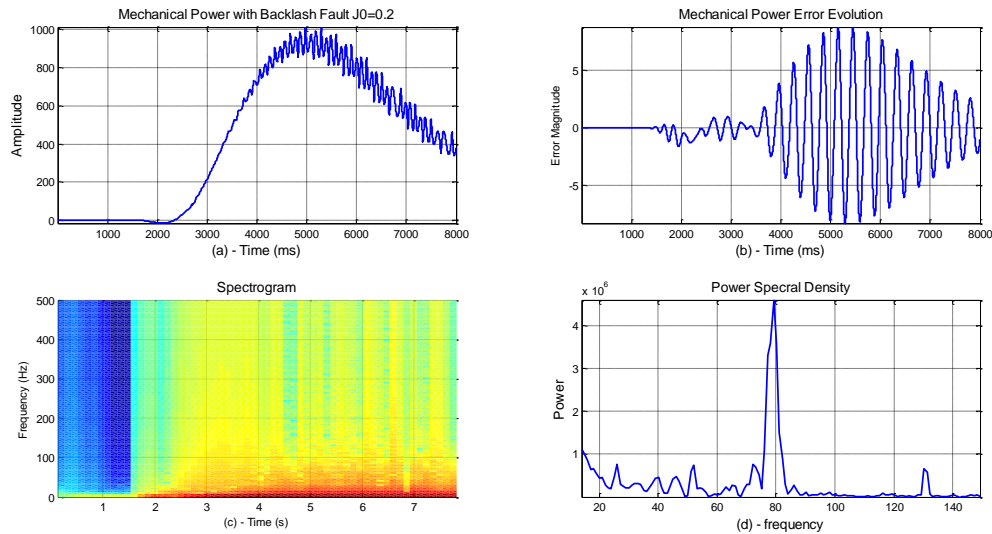


Fig.3.37- (a)- Evolution temporelle du P_m , (b)-Erreur sur P_m , (c)- Spectrogramme de (Err_P_m) et DSP de (Err_P_m) pour un défaut de backlash $J_0=0.2$ rad.

Cas_03 Spectrogramme pour un défaut de Backlash $J_0=0.3$ rad :

Les figures (**Fig.3.38** à **Fig.3.43**) illustrent : (a) l'évolution du signal temporel, (b) l'évolution de l'erreur du signal temporel, (c) Représentation temps-fréquence obtenue avec le spectrogramme et (d) la Densité Spectrale de Puissance (**DSP**) calculée à partir de l'erreur sur les grandeurs C_e , Ω_1 , Ω_2 , C_p , T_m et P_m pour un défaut de backlash de l'ordre de $J_0=0.3$ rad. A partir de ces figures, nous pouvons constater clairement qu'il y a des fluctuations fréquentielles au niveau de la **DSP** et le spectrogramme. Les amplitudes des harmoniques parasites s'amplifient davantage pour indiquer la gravité du défaut de backlash.

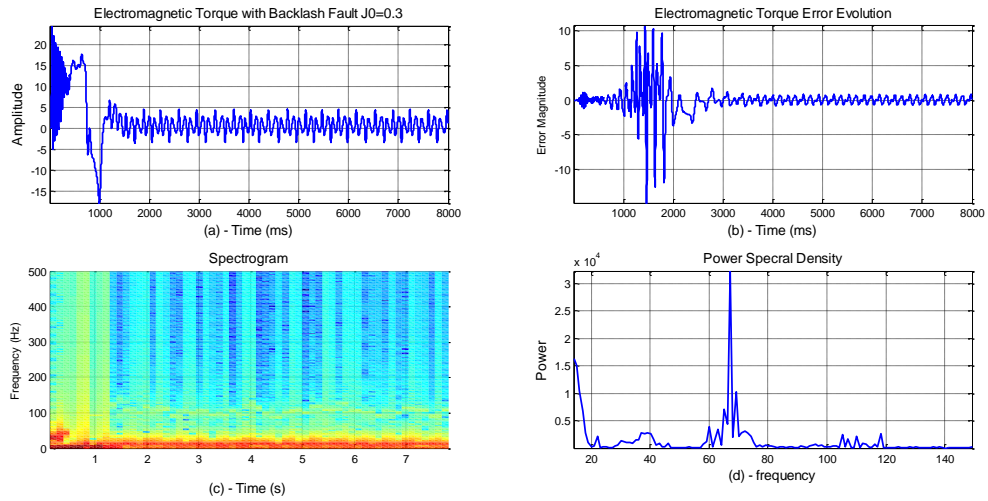


Fig.3.38- (a)- Evolution temporelle de C_e , (b)-Erreur sur C_e , (c)- Spectrogramme de (Err_C_e) et DSP de (Err_C_e) pour un défaut de backlash $J_0=0.3$ rad.

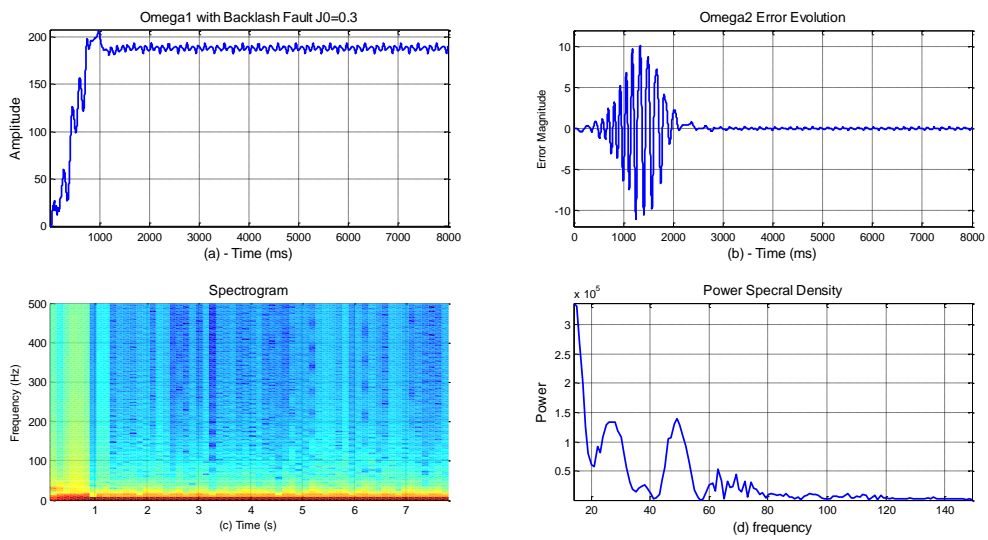


Fig.3.39- (a)- Evolution temporelle de Ω_1 , (b)-Erreur sur Ω_1 , (c)- Spectrogramme de $(Err_ \Omega_1)$ et DSP de $(Err_ \Omega_1)$ pour un défaut de backlash $J_0=0.3$ rad.

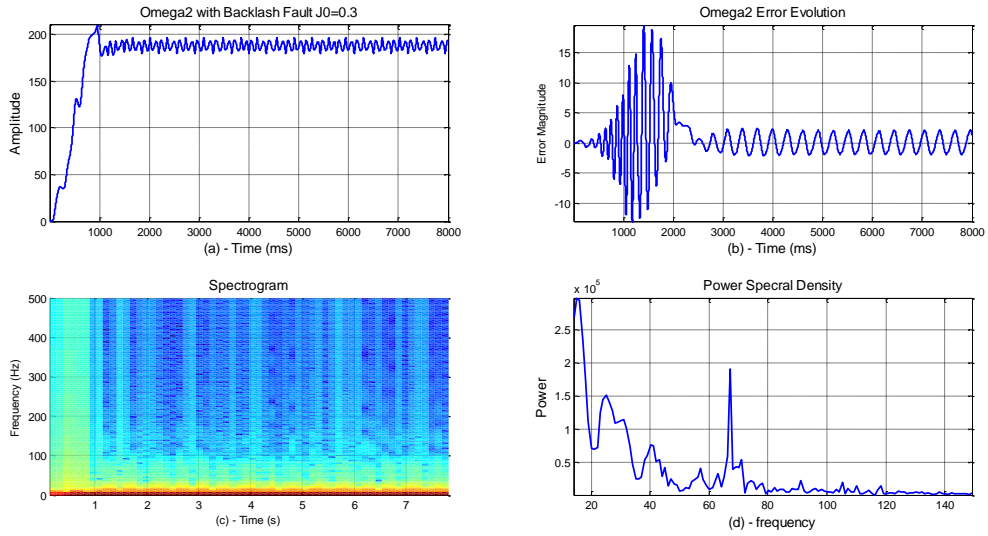


Fig.3.40- (a)- Evolution temporelle de Ω_2 , (b)-Erreur sur Ω_2 , (c)- Spectrogramme de $(Err_ \Omega_2)$ et DSP de $(Err_ \Omega_2)$ pour un défaut de backlash $J_0=0.3$ rad.

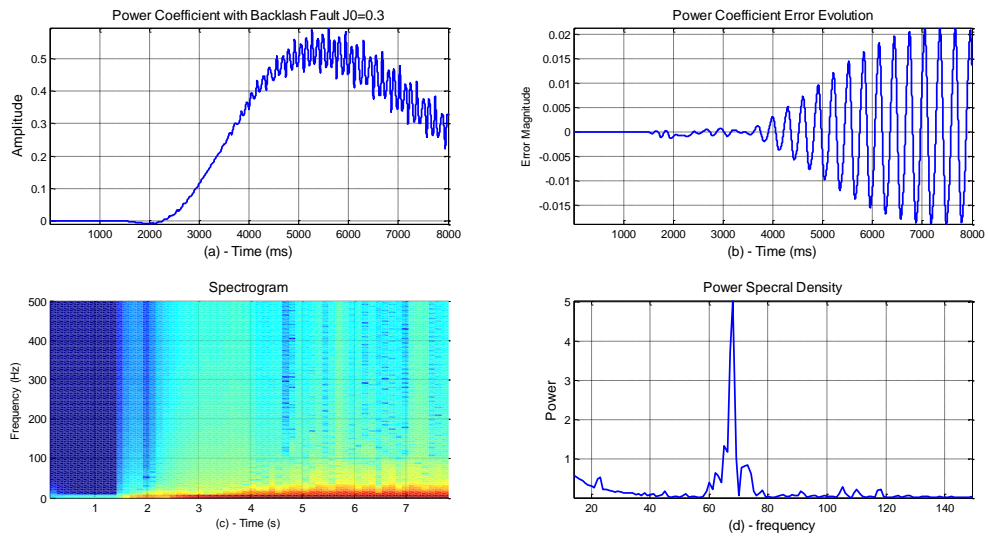


Fig.3.41- (a)- Evolution temporelle du C_p , (b)-Erreur sur C_p , (c)- Spectrogramme de $(Err_ C_p)$ et DSP de $(Err_ C_p)$ pour un défaut de backlash $J_0=0.3$ rad.

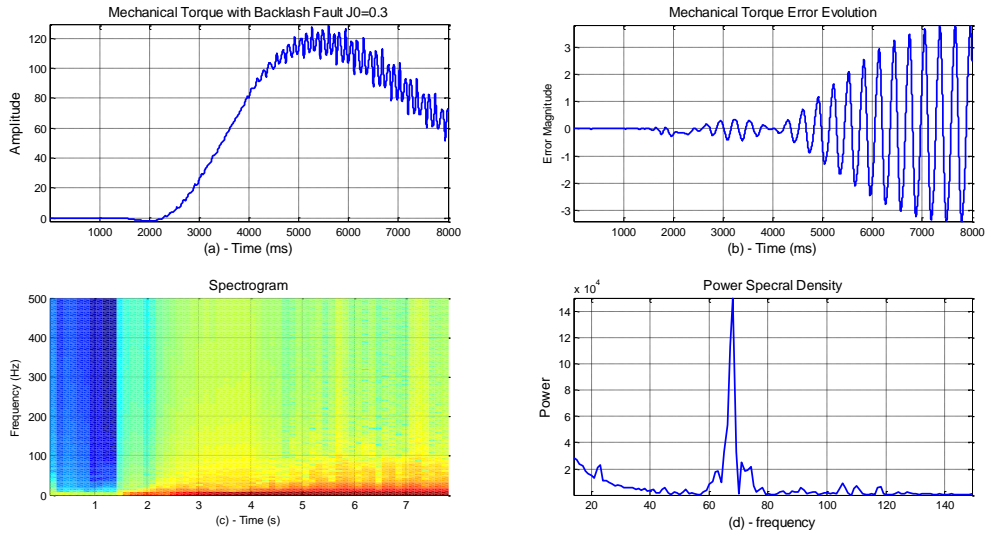


Fig.3.42- (a)- Evolution temporelle du T_m , (b)-Erreur sur T_m , (c)- Spectrogramme de (Err_T_m) et DSP de (Err_T_m) pour un défaut de backlash $J_0=0.3$ rad.

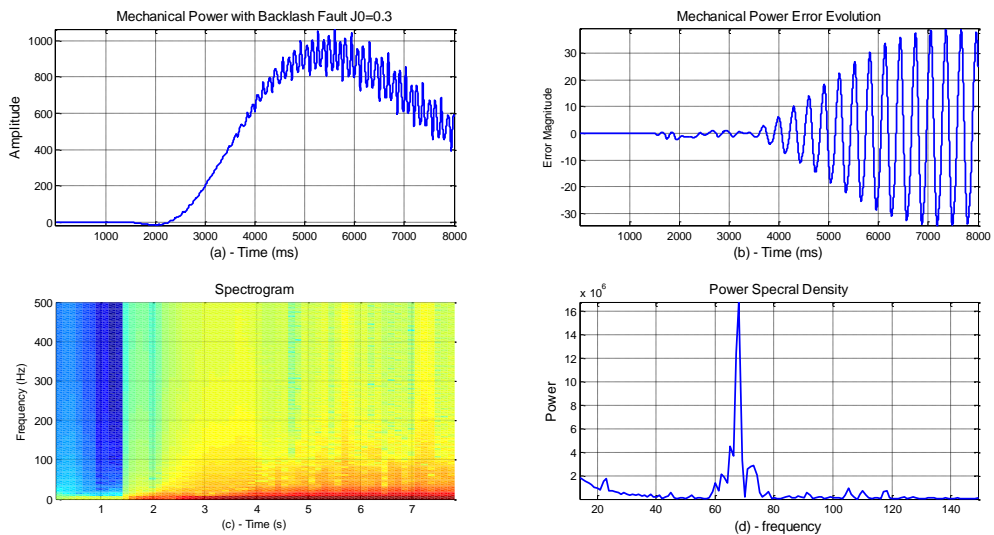


Fig3.43- (a)- Evolution temporelle du P_m , (b)-Erreur sur P_m , (c)- Spectrogramme de (Err_P_m) et DSP de (Err_P_m) pour un défaut de backlash $J_0=0.3$ rad.

Cas_04 Spectrogramme Pour un défaut de Backlash $J_0=0.4$ rad :

Les figures (**Fig.3.44** à **Fig.3.49**) montrent la sensibilité des différentes grandeurs (C_e , Ω_1 , Ω_2 , C_p , T_m et P_m) vis-à-vis l'augmentation de l'amplitude du défaut de backlash. Les mêmes constatations restent valables pour ce scénario de simulation.

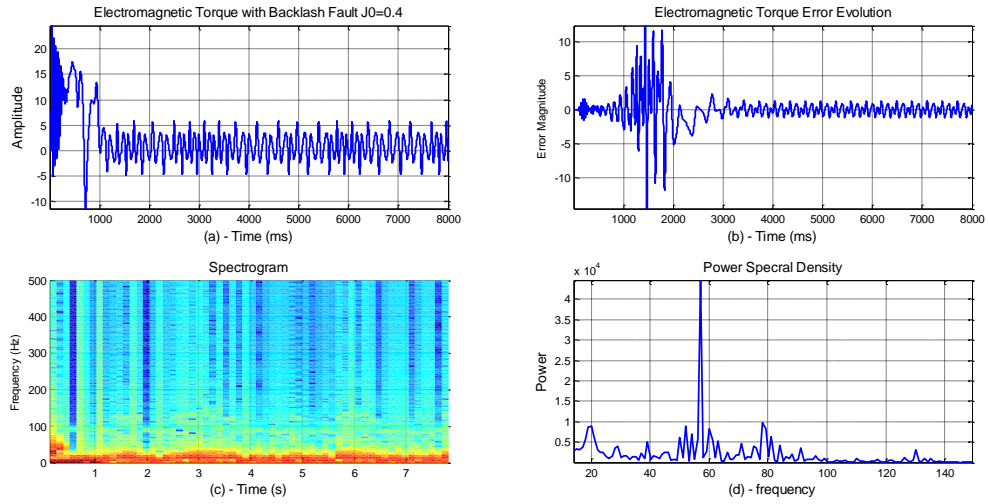


Fig.3.44- (a)- Evolution temporelle de C_e , (b)-Erreur sur C_e , (c)- Spectrogramme de (Err_C_e) et DSP de (Err_C_e) pour un défaut de backlash $J_0=0.4$ rad.

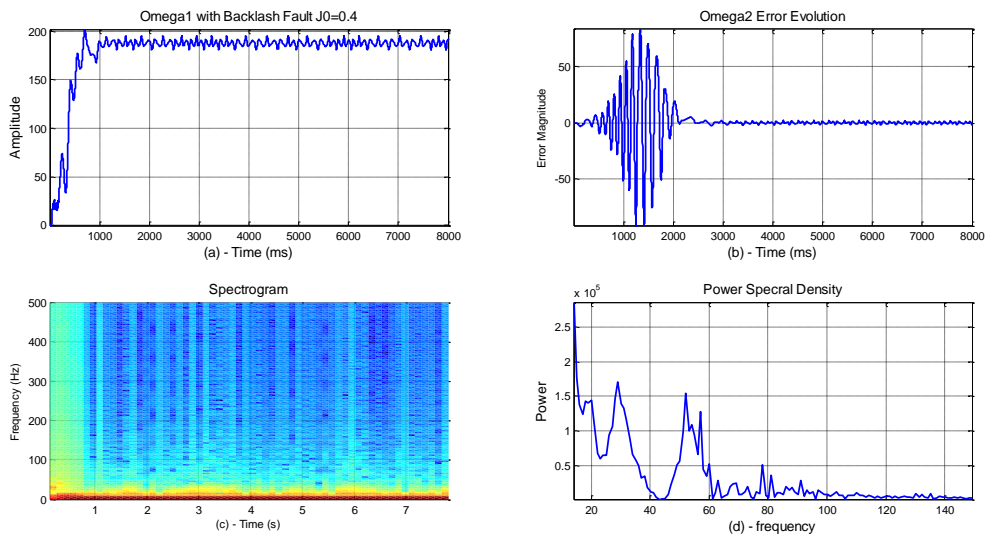


Fig.3.45- (a)- Evolution temporelle de Ω_1 , (b)-Erreur sur Ω_1 , (c)- Spectrogramme de $(Err_ \Omega_1)$ et DSP de $(Err_ \Omega_1)$ pour un défaut de backlash $J_0=0.4$ rad.

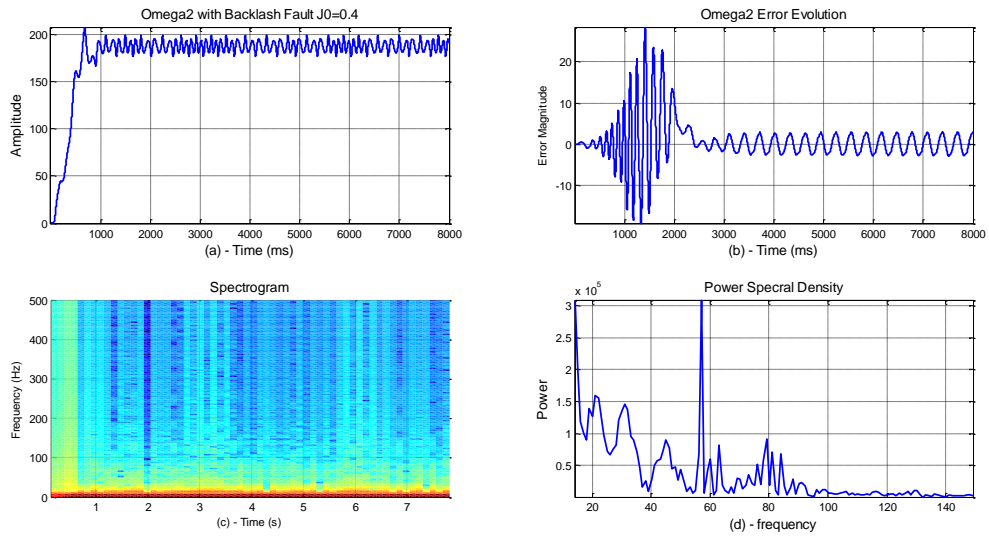


Fig.3.46- (a)- Evolution temporelle de Ω_2 , (b)-Erreur sur Ω_2 , (c)- Spectrogramme de $(Err_ \Omega_2)$ et DSP de $(Err_ \Omega_2)$ pour un défaut de backlash $J_0=0.4$ rad.

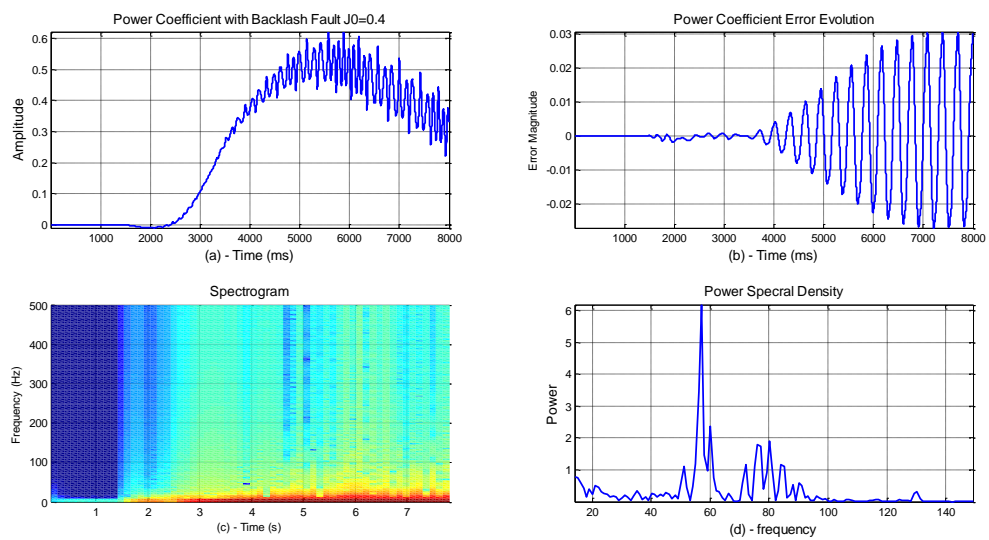


Fig.3.47- (a)- Evolution temporelle du C_p , (b)-Erreur sur C_p , (c)- Spectrogramme de $(Err_ C_p)$ et DSP de $(Err_ C_p)$ pour un défaut de backlash $J_0=0.4$ rad.

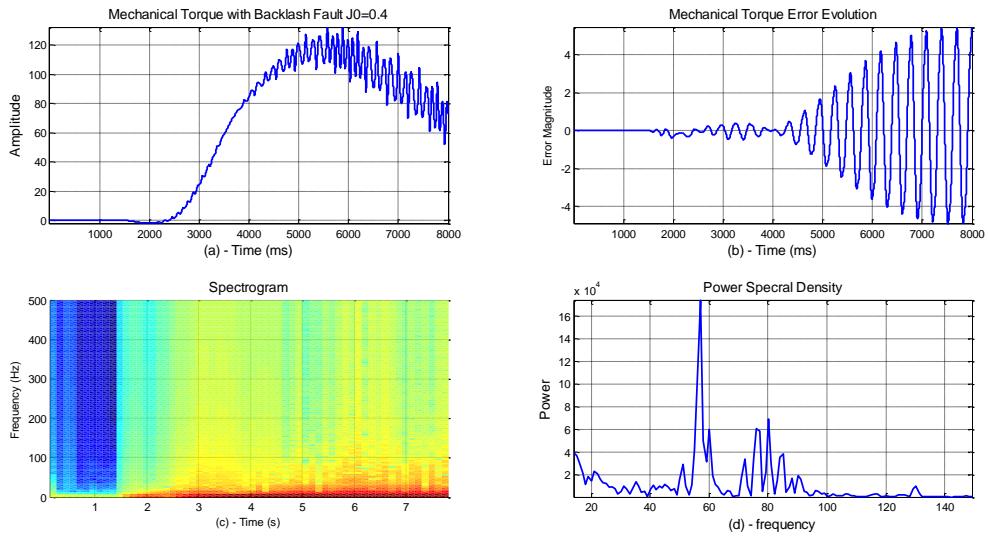


Fig.3.48- (a)- Evolution temporelle du T_m , (b)-Erreur sur T_m , (c)- Spectrogramme de (Err_T_m) et DSP de (Err_T_m) pour un défaut de backlash $J_0=0.4$ rad.

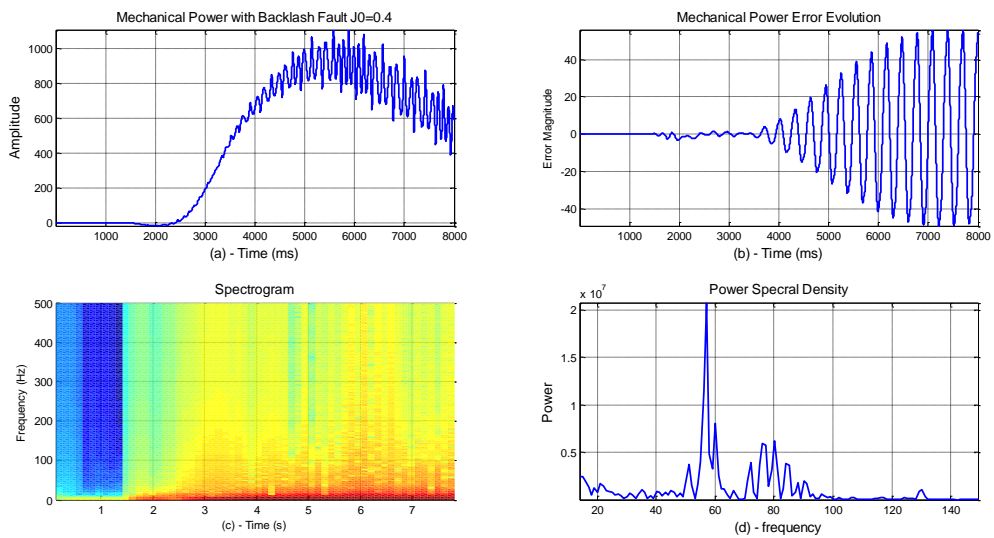


Fig.3.49- (a)- Evolution temporelle du P_m , (b)-Erreur sur P_m , (c)- Spectrogramme de (Err_P_m) et DSP de (Err_P_m) pour un défaut de backlash $J_0=0.4$ rad.

Discussion des résultats :

Les résultats de simulation, pour le cas d'estimation par le spectrogramme et la densité Spectrale de Puissance, présentent une analyse spectrale fine et précise pouvant distinguer les composantes fluctuantes qui altèrent le bon fonctionnement d'un système éolien. Pour valider cette méthode d'analyse, nous l'avons testé les mêmes grandeurs (C_e , Ω_1 , Ω_2 , C_p ,

T_m et P_m). L'examen des différentes figures montre l'apparition de ce défaut sous forme d'harmoniques de pollution par rapport à un cas de fonctionnement sain.

A travers ces figures, nous pouvons voir clairement que le signal présente des non-stationnarités qui sont par nature caractérisant un signal vibratoire. Ce type d'analyse a pour avantage d'être adapté à tout type de non-stationnarités sous l'hypothèse que pour chaque fréquence, il existe au cours du temps une partie stationnaire, par exemple un signal stationnaire par morceaux, une modulation de fréquence ou des chocs impulsifs dans un bruit stationnaire. En général, si les variations d'énergie sont suffisantes, ces non-stationnarités peuvent être détectées en temps et en fréquence. Les non-stationnarités sont illustrés par des pics (**DSP**) ou par une distribution d'énergies (Spectrogramme) qui peuvent être estimés en amplitude et en durée de chaque composante.

La détection de ce type de non-stationnarités dépend de la résolution fréquentielle choisie. Les plus importantes ont été détectées avec le spectrogramme glissant pour une taille de segments de 512 points. Par contre des motifs non-stationnaires de faible puissance et très localisés en temps, ne sont plus détectés lorsque l'on augmente la taille des segments. On retrouve le compromis classique résolution temporelle, résolution fréquentielle. Ce signal peut être analysé dans le cadre stationnaire, mais ces informations doivent être intégrées pour l'interprétation finale des motifs spectraux, en particulier, en ce qui concerne l'interprétation de la largeur de bande des motifs en partie due à ces fluctuations de fréquences. Cependant, pour effectuer un diagnostic fin et précis, l'utilisation des méthodes paramétriques est nécessaire voire obligatoire. Dans cette optique, nous avons exécuté les mêmes scénarios de simulation en utilisant la méthode de Prony et Burg.

3.5.2. Méthodes d'Analyse Spectrale Paramétriques :

Pour effectuer une analyse qualitative des défauts de backlash affectant les systèmes éoliens, nous avons sélectionné deux algorithmes, l'algorithme de Burg et l'algorithme de Prony. Les performances des méthodes proposées sont évaluées sur des signaux issus d'un simulateur d'un système éolien réalisé dans un environnement *Bond Graph* sous *20-Sim*. L'ordre des modèles des différents signaux régissant le comportement des différentes grandeurs est calculé en fonction de l'ordre des erreurs de prédiction calculées à partir du

signal estimé et le l'observation de référence. Les résultats obtenus sont illustrés sur les figures ci-dessous.

Pour des raisons de simplification, nous avons sélectionné deux scénarios correspondant à un défaut de *backlash* de l'ordre de $J_0 = 0.2 \text{ rad}$ et $J_0 = 0.3 \text{ rad}$ mesurés sur les deux grandeurs, le couple électromagnétique C_e et la vitesse lente Ω_1 .

Cas_01 : La méthode de Prony et Burgs pour le couple électromagnétique et la vitesse Oméga1 avec un Backlash $J_0=0.2 \text{ rad}$:

Les figures (**Fig.3.50, Fig.3.51, Fig.3.53, Fig.3.54**) illustrent : (a) l'évolution de l'erreur de référence du signal temporel. Les figures (**Fig.3.50, Fig.3.51, Fig.3.53, Fig.3.54**) : (b et c) présentent l'évolution de l'erreur estimée par la méthode de Prony et la méthode de burg respectivement. Les figures (**Fig.3.51, Fig.3.54**) (d, e et f) présentent la densité spectrale calculée par **FFT** sur l'évolution de l'erreur de référence, l'erreur estimée par la méthode de Prony et l'erreur estimée par la méthode de Burg respectivement sur les grandeurs $C_e, \Omega_1, \Omega_2, C_p, T_m$ et P_m pour un défaut de backlash de l'ordre de $J_0=0.2 \text{ rad}$.

Une expertise de l'estimation spectrale de ces signaux peut permettre de donner des indications sur une éventuelle altération causée par le phénomène de backlash. Dans la simulation présentée ci-dessous, on va comparer l'estimation du spectre des erreurs des grandeurs mesurées en utilisant la **FFT** appliquée directement sur le signal erreur et l'estimation de la **DSP** appliquée sur le modèle **AR** régissant ces signaux d'erreurs. Sur les Figures (**Fig.3.52, Fig.3.55**), on peut voir le résultat de l'analyse spectrale de ce signal par les deux méthodes. L'estimateur par la méthode de Prony et la méthode autorégressive de Burg. Le problème consiste à identifier tout d'abord le modèle **AR(P)** et ensuite calculer le spectre en se basant les coefficients du modèle estimé.

Les résultats obtenus montrent l'efficacité des hypothèses établies dans le cahier des charges. L'influence du phénomène de backlash est clairement visible en utilisant les méthodes d'analyse spectrale, et surtout, les méthodes d'analyse spectrale paramétrique. Un deuxième avantage pour les méthodes d'analyse spectrale paramétrique concerne les signaux non stationnaires qui sont mieux analysés par cette catégorie d'approches.

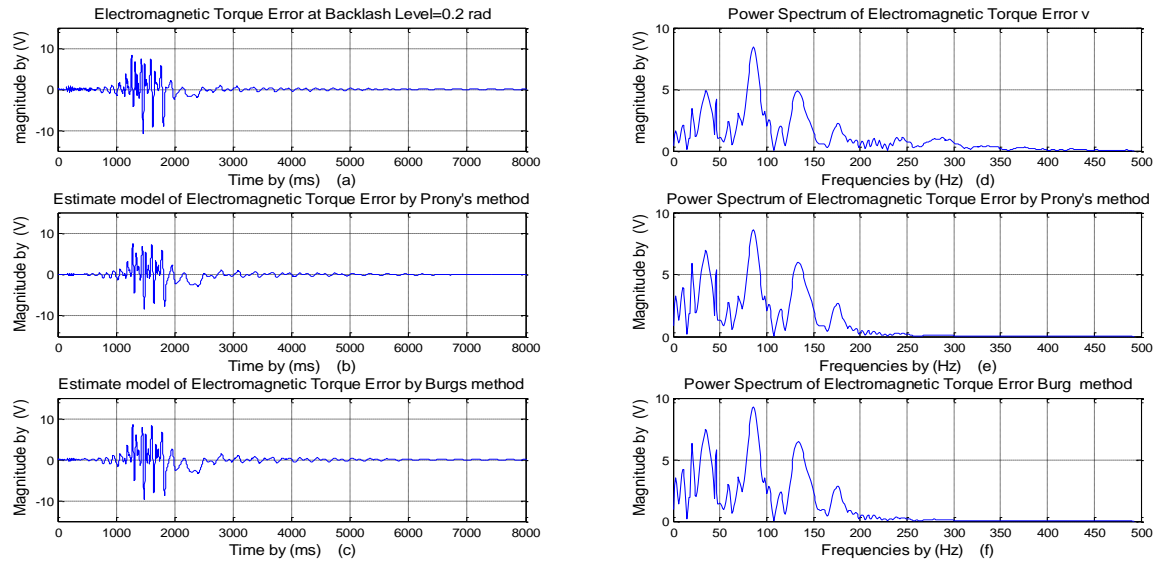


Fig.3.50- (a)- Evolution temporelle du Err_{C_e} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur C_e , par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et FFT de Err_{C_e} estimée par Prony et la FFT de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.

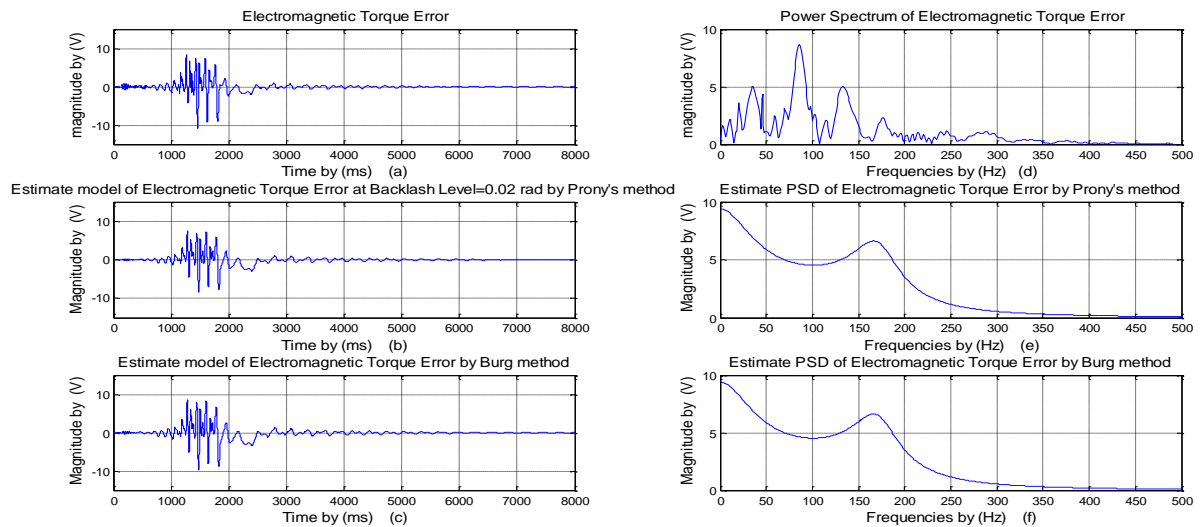


Fig.3.51- (a)- Evolution temporelle du Err_{C_e} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur C_e , par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et DSP de Err_{C_e} estimée par Prony et la DSP de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.




Fig.3.52- (a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_{C_e}) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_{C_e}) pour $J_0=0.2$ rad.

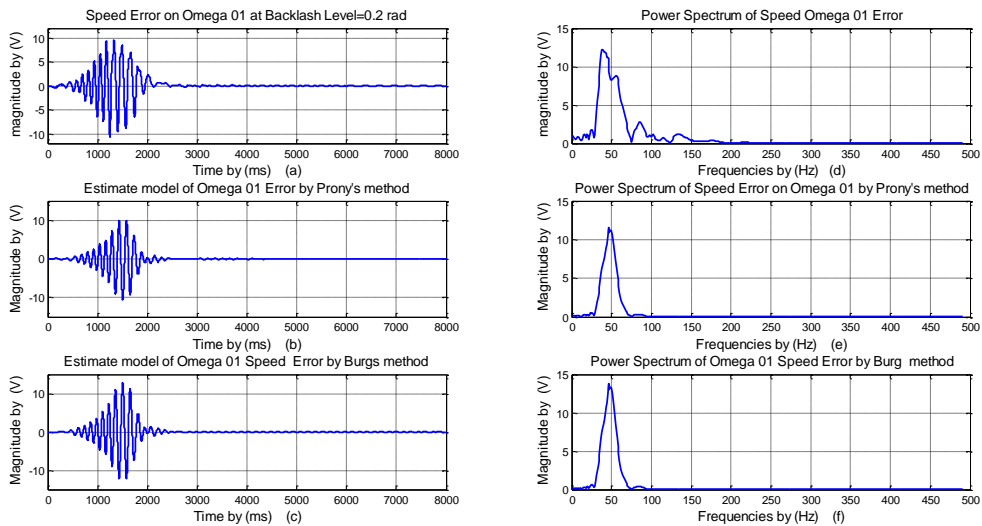


Fig.3.53- (a)- Evolution temporelle du Err_{Ω_1} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur Ω_1 par la méthode de Burg, (d) FFT de Err_{Ω_1} de référence, (e) et FFT de Err_{Ω_1} estimée par Prony et la FFT de Err_{Ω_1} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.

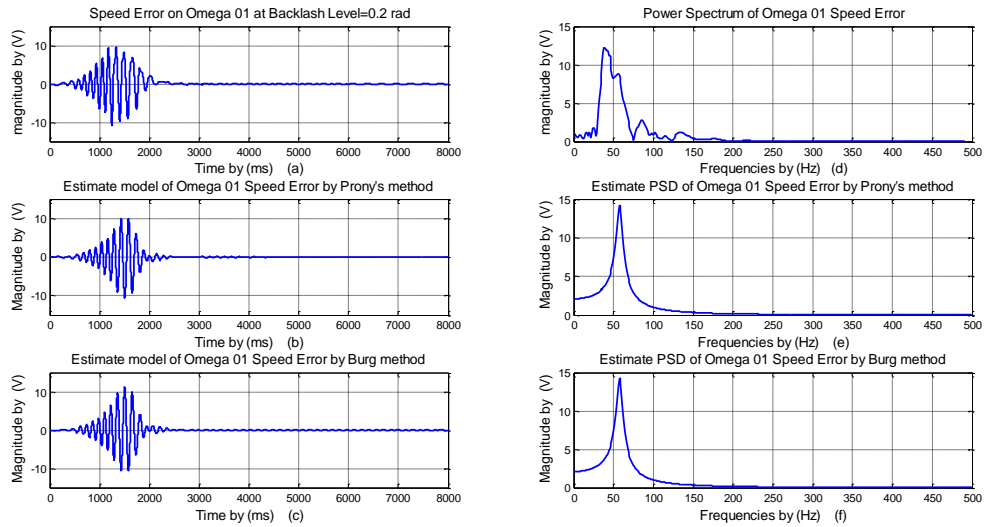


Fig.3.54- (a)- Evolution temporelle du Err_{Ω_1} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur Ω_1 , par la méthode de Burg, (d) FFT de Err_{Ω_1} de référence, (e) et DSP de Err_{Ω_1} estimée par Prony et la DSP de Err_{Ω_1} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.2$ rad.




Fig.3.55- (a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_{Ω_1}) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_{Ω_1}) pou $J_0=0.2$ rad.

Discussion des résultats :

Une expertise de l'estimation spectrale de ces signaux peut permettre de donner des indications sur une éventuelle altération causée par le phénomène de backlash. Dans la simulation présentée ci-dessous, on va comparer l'estimation du spectre des erreurs des grandeurs mesurées en utilisant la **FFT** appliquée directement sur le signal erreur et l'estimation de la **DSP** appliquée sur le modèle **AR** régissant ces signaux d'erreurs.

Sur les Figures (Fig.3.50, Fig.3.51, Fig.3.53, Fig.3.54), on peut voir le résultat de l'analyse spectrale de ce signal par les deux méthodes. L'estimateur par la méthode de Prony et la méthode autorégressive de Burg. Le problème consiste à identifier tout d'abord le modèle $AR(P)$ et ensuite calculer le spectre en se basant les coefficients du modèle estimé. Les résultats obtenus montrent l'efficacité des hypothèses établies dans le cahier des charges. L'influence du phénomène de backlash est clairement visible en utilisant les méthodes d'analyse spectrale, et surtout, les méthodes d'analyse spectrale paramétrique. Un deuxième avantage pour les méthodes d'analyse spectrale paramétrique concerne les signaux non stationnaires qui sont mieux analysés par cette catégorie d'approches.

Cas_02 - La méthode de Prony et Burgs pour le couple électromagnétique avec un Backlash $J_0=0.3$ rad :

Les figures (Fig.3.56, Fig.3.57, Fig.3.59, Fig.3.60) illustrent : (a) l'évolution de l'erreur de référence du signal temporel. Les figures (Fig.3.56, Fig.3.57, Fig.3.59, Fig.3.60) : (b et c) présentent l'évolution de l'erreur estimée par la méthode de Prony et la méthode de burg respectivement. Les figures (Fig.3.56, Fig.3.57, Fig.3.59, Fig.3.60) :(d, e et f) présentent la densité spectrale calculée par FFT sur l'évolution de l'erreur de référence, l'erreur estimée par la méthode de Prony et l'erreur estimée par la méthode de Burg respectivement sur les grandeurs $C_e, \Omega_1, \Omega_2, C_p, T_m$ et P_m pour un défaut de backlash de l'ordre de $J_0=0.3$ rad.

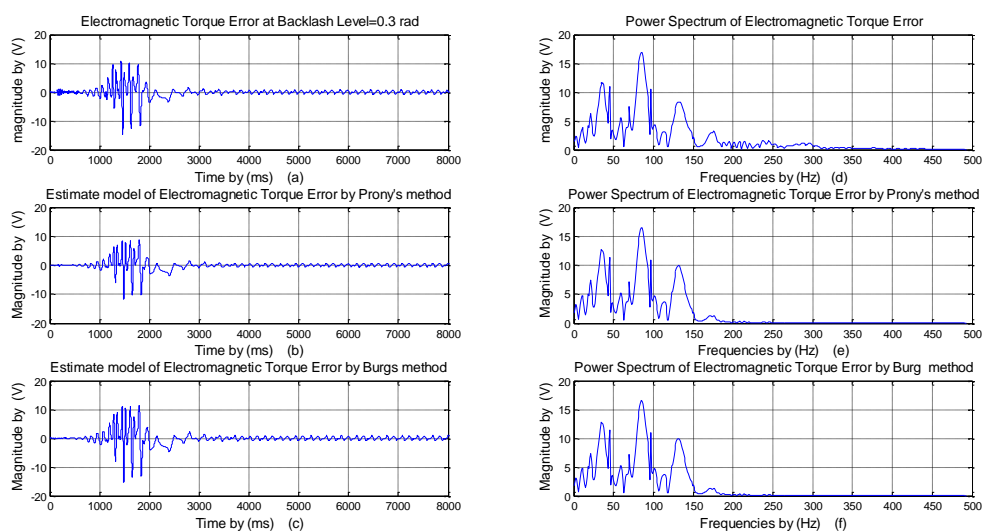


Fig.3.56- (a)- Evolution temporelle du Err_{C_e} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur C_e , par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et FFT de Err_{C_e} estimée par Prony et la FFT de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad.

La figure (Fig.3.57 : e, f) montre la densité spectrale de puissance pour le couple électromagnétique et leur erreur pour un défaut de backlash $j_0=0.3$ avec les méthodes de prony et burg.

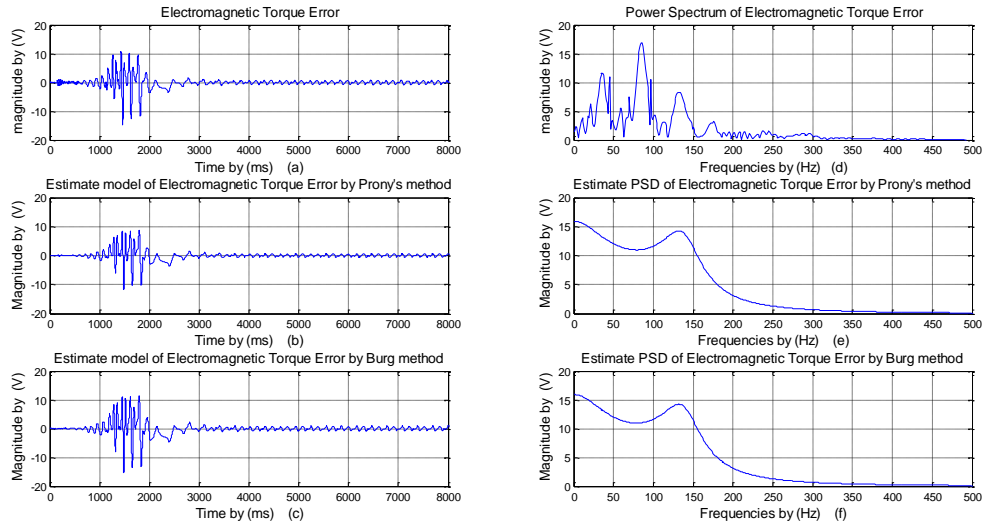


Fig.3.57- (a)- Evolution temporelle du Err_{C_e} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur C_e , par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et DSP de Err_{C_e} estimée par Prony et la DSP de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad.




Fig.3.58- (a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_{C_e}) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_{C_e}) pou $J_0=0.3$ rad.

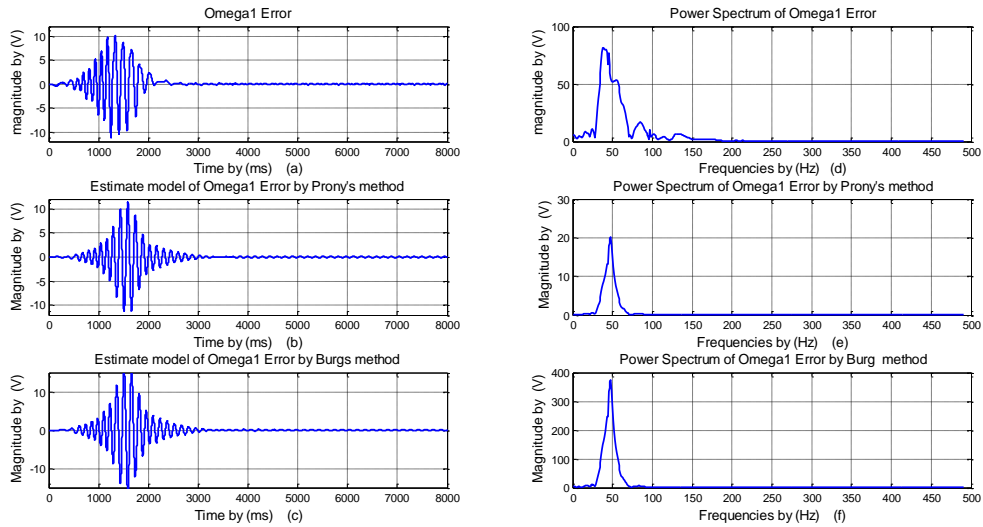


Fig.3.59- (a)- Evolution temporelle du Err_{Ω_1} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur Ω_1 par la méthode de Burg, (d) FFT de Err_{Ω_1} de référence, (e) et FFT de Err_{Ω_1} estimée par Prony et la FFT de Err_{Ω_1} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad.

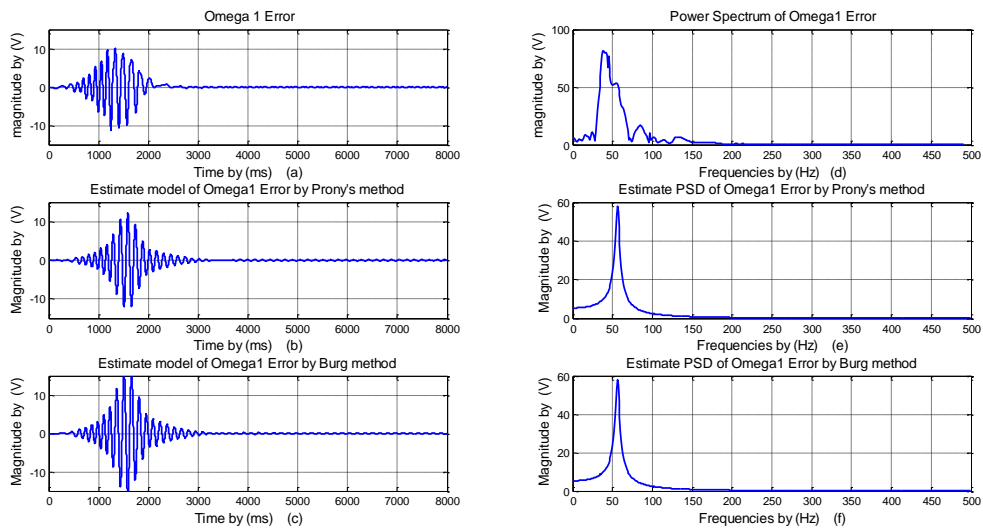


Fig.3.60- (a)- Evolution temporelle du Err_{C_e} , (b)-Erreur Estimée sur C_e , par la méthode de Prony, (c)- Erreur Estimée sur C_e , par la méthode de Burg, (d) FFT de Err_{C_e} de référence, (e) et DSP de Err_{C_e} estimée par Prony et la DSP de Err_{C_e} estimée par la méthode de Burg pour un défaut de backlash $J_0=0.3$ rad.




Fig.3.61 - (a)- Spectres par FFT de l'erreur du Couple électromagnétique (Err_{Ω_1}) et (b) la DSP avec les Méthodes de prony et Burgs pour (Err_{Ω_1}) pour $J_0=0.3$ rad.

Discussion des résultats :

Sur les Figures (Fig.3.56, Fig.3.57, Fig.3.59, Fig.3.60), illustrent les résultats de l'analyse spectrale de ce signal par les deux méthodes, la méthode de Prony et la méthode Burg. Différents essais sur ces signaux synthétiques ont permis de donner un ordre d'idée des techniques d'analyse spectrale. Lorsque la variance augmente, l'amplitude des pics du bruit augmente : la bande équivalente diminue donc l'amplitude d'un pic fréquence pure augmente. Les deux effets se compensent en partie. Cependant, le paramètre qui tient le plus compte des performances de l'estimateur et qui permet de distinguer l'importance d'un pic par rapport au fond est la probabilité de fausse alarme du détecteur qui permet de détecter le pic d'intérêt.

3.6. Conclusion

Dans ce chapitre, nous avons présenté différentes techniques d'analyse spectrale pour la détection et l'analyse des défauts, Une analyse profonde a été effectuée dans le domaine temporel et fréquentiel en vue d'extraire les paramètres pertinents pour un éventuel diagnostic et classification. Nous avons développé des méthodes d'analyse spectrale paramétrique et non paramétrique pour pouvoir discriminer l'état défectueux par rapport à un état sain.

Bibliographies

- [1] **H. e. M. Majid**, *Outils d'aide au diagnostic basés sur l'analyse spectrale*, 2007.
- [2] **M. Kunt et al.**, *Techniques Moderne de Traitement Numérique du Signal, Collection Electricité : Traitement de l'Information, vol. 1, Ed. Polytechniques, 1991.*
- [3] **J. Nohrden**, *Spectral estimation using nonuniform sampling, massachusetts institute of technology, 1995.*
- [4] **B. KARIM**, *Surveillance Automatisée de Processus Industriels Complexes, Boumerdès, 2014.*
- [5] **N. Moreau**, *Modélisation, estimation spectrale, Paris: ed. Télécom, 1990.*
- [6] **W. g. e. D. Sharp**, «*Estimation of power spectra with finite-order auto-regressive models*», vol. 1/2, I. Trans, Éd., 1973, pp. 367-369.
- [7] **J. S. L. Marple**, *Conventional Fourier Autoregressive and Special ARMA Methods of Spectrum Analysis, Stanford Univ, 1976.*
- [8] **T. J. U. & T. N. Bishop**, *Maximum Entropy Spectral Analysis and Autoregressive Decomposition, vol. 13, 1975, pp. 183-200.*
- [9] **R. L. Kashyap**, *Inconsistency of the AIC Rule for Estimating the Order of Autoregressive Models, vol. 25, Automat, 1980, pp. 996-998.*
- [10] **M. Pagano**, *Estimation of Models of Autoregressive Signal plus White Noise, vol. 2, Statistics, 1974, pp. 99-108.*
- [11] **M. E. O. & G. H. S. J. Fryer**, *Deconvolution and Spectral Estimation Using Final Prediction Error, vol. 40, 1975, pp. 411-425.*
- [12] **R. H. Jones**, *Autoregressive Order Selection, vol. 41, 1976, pp. 771-773.*
- [13] **J. P Toomey**, «*High resolution Frequency measurement by linear prediction,*» *IEEE Trans. Aerospace Electron . syst., Vols. 1 sur 2AES-16, pp. 517-525, july 1980.*
- [14] **H. Sakai**, *Statistical Properties of AR Spectral Analysis, vol. 27, 1979, pp. 402-409.*
- [15] **J. Marple**, *Frequency Resolution of High-Resolution Spectrum Analysis Techniques, 1978, pp. 19-35.*
- [16] **B. Gérard et C. Maurise**, *Digital signal and image processing using matlab, USA: ISTE, 2006.*
- [17] **D. Alain et e. al**, «*Estimation fréquentielle et Echantillonnage: les bon choix,*» dix-septième colloque GRETSI, Vannes, pp. 235-238, 1999.
- [18] **M. Hayes**, *Digital signal processing and modeling, New York: willey, 1996.*
- [19] **F. R. Paulo et e. Al**, *power systems signal processing for smart grids, John wiley & sons, 2014.*
- [20] **M. B. Priestley**, *Spectral Analysis and Time Series., London, U.K, 1981.*
- [21] **A. T. W**, *The Statistical Analysis of Time Series., New York:Wiley, 1971.*
- [22] **S. P et M. R. L**, «*Introduction to Spectral Analysis,*» Upper Saddle River NJ: Prentice-Hall, 1997.
- [23] **y.-w. Youn et e. Al**, «*Music-based Diagnosis algorithm for identifying broken rotor bar fault in induction motors using flux signal,*» *Journal of electrical engineering & technology, JEET, vol. 8, n° 12, pp. 288-294, 2013.*

- [24] **M. Terre**, *Traitement numérique du signal*, vol. 3.2, Ecole Nation. Super, 2003.
- [25] **V. Pesarenko**, «The retrieval of harmonics from a covariance function,» *geophysics journal of the royal astronomical Society*, vol. 33, pp. 347-366, 1973.
- [26] **V. Pesarenko**, ««The retrieval of harmonics from a covariance function,»» *geophysics journal of the royal astronomical Society*, vol. 33, pp. 347-366, 1973.
- [27] **R. J. Keeler**, *Uncertainties in Adaptive Maximum Entropy Frequency Estimators*, NOAA Tech, Rep. ERL-105-WPL53, 1979.

Chapitre IV

Table des matières

4. Détection Et Classification Des Défauts	117
4.1. Introduction	117
4.2. Les différents approches de détection et de classification des défauts	118
4.2.1. Détection et classification simultanées	118
4.2.2. Détection et classification successives	119
4.3. Etat de l'art sur les méthodes de classification.....	119
4.3.1. Classification non-supervisée	120
4.3.1.1. L'algorithme des centres mobiles	120
4.3.2. Classification supervisée	121
4.3.2.1. Les arbres de décision	121
4.3.2.2. Les machines à support de vecteurs (SVM).....	121
4.3.2.3. Les classificateurs de Bayes	122
4.3.2.4. Les réseaux de neurones	122
4.4. Les grandes familles des réseaux de neurones.....	123
4.4.1. Les réseaux feed-forward	123
4.4.2. Les réseaux auto-organisés.....	123
4.4.3. Les réseaux récurrents.....	124
4.4.4. Les réseaux à résonance.....	124
4.5. Propriétés des réseaux de neurones artificiels.....	124
4.5.1. Apprentissage et mémoire	124
4.5.2. Sous-apprentissage, généralisation et sur-apprentissage	125
4.6. Architectures neuronales les plus utilisées en diagnostic	126
4.7. Réseau de neurones à Fonctions de Bases Radiales (RBF)	127
4.8. Extraction des paramètres de classification	133
4.8.1. Standard deviation	133
4.8.2. Kurtsis	134
4.8.3. Central moment.....	134
4.8.4. Wavelet energy	134
4.8.5. The total energy.....	134
4.9. Décomposition du paquet d'ondelettes.....	134
4.10. Reconnaissance et classification.....	137
4.11. Distribution des niveaux d'énergies (Multi Level Energy : ME).....	138
4.12. Les résultats de simulations.....	138
4.13. Conclusion.....	164

Bibliographies 166

Détection et Classification des Défauts

4

Ce chapitre est consacré à la mise en œuvre d'une procédure de détection basée sur l'évaluation de la **ME** (Multi-level-Energy) et une classification en utilisant les réseaux de RBF pour discriminer entre un cas sain, un défaut mécanique et un défaut électrique. Le calcul de la **ME** est effectué en utilisant la distribution de l'énergie spectrale calculée à partir des coefficients de détails issus d'une décomposition en ondelette appliquée sur les résidus discriminant entre un cas sain et un cas défectueux. La phase de classification est exécutée en utilisant vecteurs primitifs constitués par des paramètres statistiques.

4.1. Introduction

En traitement du signal, la détection et la classification interviennent quand une décision doit être prise parmi un nombre fini d'hypothèses concernant la nature et la forme du signal observé (mesuré). La détection d'un signal consiste à décider si la forme observée contient seulement une mesure non bruitée ou bien une signature masquée par le bruit. Un détecteur permet donc de choisir entre deux hypothèses (**Fig.4.1**) : l'hypothèse H_0 qui suppose que la mesure observée est toujours dans les normes, cependant, l'hypothèse H_1 indique que la signature mesurée est soumise à une dérive par rapport à un cas sain. Cette dérive se manifeste sous forme d'une violation d'un seuil discriminant entre un mode de fonctionnement normal et un mode de fonctionnement en défaut. On peut réaliser la détection par la comparaison d'une statistique à une valeur de seuil donnée.




Fig.4.1- Schéma bloc de la détection.

La classification permet d'affecter la signature détectée à une classe parmi K classes (hypothèses) prédéfinies de signaux, Ω_i , $i = 1, \dots, k, K$ (**Fig.4.2**). Cette décision est de préférence effectuée dans un espace de représentation adapté, obtenu à l'issue d'une étape de prétraitement ou de paramétrisation préservant au mieux la capacité de discrimination entre

les classes. Le module de classification apparait comme l'extension d'un module de détection, cette fois-ci non binaire, mais multi-classes.



Fig.4.2- Schéma bloc de la classification.

L'objectif de la théorie de détection et de classification est de concevoir des détecteurs et des classifieurs qui minimisent par exemple le nombre d'erreurs de décision. Dans l'optique de détection et de classification de défauts (Ω_i : classe de défaut de type i), deux approches principales pour l'agencement des deux fonctions détection et classification vont être présentées.

4.2. Les différentes approches de détection et de classification des défauts

La première approche abordée est l'approche de détection et classification simultanées de défauts qui consiste à décomposer le problème global en sous-problèmes particuliers de détection et classification à résoudre. La seconde approche réalise la détection et la classification de manière successive en traitant les deux problématiques séparément.

4.2.1. Détection et classification simultanées

Selon cette approche, les phases de détection et de classification sont effectuées simultanément selon le synoptique de la figure (Fig.4.3). Le problème global est décomposé en autant de sous-problèmes que de classes. Ces sous-problèmes peuvent être résolus parallèlement ou séquentiellement. La figure (Fig.4.3) montre l'enchaînement des sous-problèmes comme un arbre de décision [1]. L'arbre est composé de cellules (ou nœuds), où chaque cellule résout un sous-problème de détection et classification.




Fig.4.3- Approche de détection et classification simultanées.

4.2.2. Détection et classification successives

Cette approche hiérarchisée de détection puis de classification se décompose comme indiqué sur la figure (Fig.4.4).




Fig.4.4- Approche de détection et classification successives.

Les signaux mesurés (observés) sont, dans un premier temps, analysés de manière simple dans le bloc de détection pour décider entre \mathbf{H}_0 (pas de défauts) et \mathbf{H}_1 (présence de défaut).

A chaque détection, une fenêtre d'observation est ouverte et l'ensemble des signaux présents dans cette fenêtre est transmis au bloc de classification (Fig.4.4). Dans le contexte de reconnaissance des formes, une phase de prétraitement s'avère nécessaire avant la classification proprement dite. Une fois une signature de défaut détectée et prétraitée, une procédure de classification est mise en œuvre afin d'affecter chaque observation à une classe prédéfinie de défauts. La validation de ces opérations conditionne les performances de la détection et de la classification. Cette approche de détection et classification successives est employée pour la détection et la classification des défauts mécaniques ou électriques.

4.3. Etat de l'art sur les méthodes de classification

Dans un problème de classification, la tâche est d'affecter une observation à une classe ou une catégorie prédéfinie. Il existe deux contextes de mise en œuvre des méthodes de classification : les méthodes supervisées et les méthodes non supervisées. Si on dispose de données (observations) labellisées (dont la classe d'appartenance est connue), on parlera de classification supervisée, sinon on parlera de classification non supervisée. Dans la suite, on ne considèrera que les méthodes supervisées.

4.3.1. Classification non-supervisée

Cette classification est aussi appelée "classification automatique", "clustering" ou encore "regroupement". Dans ce type de classification on est amené à identifier les populations d'un ensemble de données. On suppose qu'on dispose d'un ensemble d'objets que l'on note par $X = \{x_1, x_2, \dots, x_N\}$ caractérisé par un ensemble de descripteurs D , l'objectif du clustering est de trouver les groupes auxquels appartiennent chaque objet x qu'on note par $C = \{C_1, C_2, \dots, C_n\}$. Ce qui revient à déterminer une fonction notée Y qui associe à chaque élément de X un ou plusieurs éléments de C . Il faut pouvoir affecter une nouvelle observation à une classe. Les observations disponibles ne sont pas initialement identifiées comme appartenant à telle ou telle population. L'absence d'étiquette de classe est un lourd handicap qui n'est que très partiellement surmontable. Seule l'analyse de la répartition spatiale des observations peut permettre de "deviner" où sont les véritables classes. Les deux difficultés essentielles que rencontre la classification non supervisée sont les suivantes :

- S'il est naturel de reconnaître comme "appartenant à une même classe" des observations regroupées dans une même zone de forte densité, il n'en est pas de même dans des zones de faible densité. En particulier, on peut s'attendre à ce que la définition des frontières entre les classes soit sujette à caution, et pour le moins hasardeuse ;
- L'œil humain est un extraordinaire outil de classification non supervisée. Malheureusement, il n'est opérationnel que pour des données bidimensionnelles, alors que les données que rencontre l'analyste sont couramment décrites par des dizaines de variables ou plus. Il s'avère que reproduire les performances de l'œil humain dans des espaces de grandes dimensions est un exploit aujourd'hui hors d'atteinte des machines.

Parmi les méthodes non-supervisées les plus utilisées, citons deux types d'approches : les centres mobiles (k-means) et la classification hiérarchique.

4.3.1.1. L'algorithme des centres mobiles

L'objectif de la méthode est de partitionner en différentes classes des individus pour lesquels on dispose des mesures. On représente les individus comme des points de l'espace ayant pour coordonnées ces mesures. On cherche à regrouper autant que possible les individus les plus semblables (du point de vue des mesures que l'on possède) tout en séparant les classes le mieux possible les unes des autres. Ici encore (comme dans le cas de la classification hiérarchique ascendante) on choisit de procéder **de façon automatique**, c'est à dire qu'on ne cherche pas à utiliser l'expertise que l'on aurait des individus pour trouver des regroupements

avec ce que l'on connaît les concernant mais plutôt un moyen de **faire apparaître**, uniquement à partir des mesures, des ressemblances et des différences à priori peu visibles.

La méthode des centres mobiles s'applique lorsqu'on sait à l'avance combien de classes on veut obtenir.

4.3.2. Classification supervisée

Dans le contexte supervisé on dispose déjà d'exemples dont la classe est connue et étiquetée. Les données sont donc associées à des labels des classes notés $\theta = \{q_1, q_2, \dots, q_n\}$. L'objectif est alors d'apprendre à l'aide d'un modèle d'apprentissage des règles qui permettent de prédire la classe des nouvelles observations ce qui revient à déterminer une fonction Cl qui à partir des descripteurs (D) de l'objet associe une classe q_i et de pouvoir aussi affecter toute nouvelle observation à une classe parmi les classes disponibles. Ceci revient à la fin à trouver une fonction qu'on note Y_s qui associe chaque élément de X un élément de Q . On construit alors un modèle en vue de classer les nouvelles données. Parmi les méthodes supervisées on cite : les k-plus proches voisins, les arbres de décision, les réseaux de neurones, les machines à support de vecteurs (**SVM**) et les classificateurs de Bayes.

4.3.2.1. Les arbres de décision

Les arbres de décision (**AD**) sont des techniques très employées dans les cas où il est important de trouver des règles afin de définir la classification. Les caractéristiques de la structure des arbres permettent une représentation interprétable des résultats. Un arbre de décision correspond à une structure arborescente formée par des nœuds internes et terminaux reliés par des branches. Pour arriver à chaque nœud terminal, il y a une trajectoire unique qui débute avec le nœud racine. La trajectoire correspond à une règle de décision (de la classe du document) formée par une conjonction (**ET**) de plusieurs conditions de test. Les algorithmes les plus représentatifs des arbres de décision sont ID3 [2], C4 [3]

4.3.2.2. Les machines à support de vecteurs (SVM)

Les machines à support vectoriel (**SVM**) s'apparentent aux classifieurs linéaires, dans le sens où elles tentent de séparer l'espace en deux mais certaines manipulations mathématiques les rendent adaptables à des problèmes non linéaires. L'idée des **SVM** a été introduite par [4] pour les machines d'apprentissage (**ML**). Joachim l'introduit en Catégorisation de Textes [5] puis les a utilisés dans plusieurs travaux.

Les algorithmes de classification linéaire se basent sur un profil [6], [7]. Le profil est un vecteur de termes pondérés construit pour chaque catégorie, dans le but de les représenter d'une façon générale. Ce vecteur est construit à l'aide des documents d'apprentissage, quand un nouveau texte, doit être classé, il est comparé à ce vecteur « type ». L'avantage de cette approche est qu'elle produit un classifieur compréhensible par l'humain, dans le sens où le profil de la catégorie peut être interprété facilement. Par contre, l'inconvénient principal de tous les algorithmes linéaires est que l'espace est divisé en seulement deux portions, ce qui peut être restrictif, car tous les problèmes ne sont pas nécessairement linéairement séparables.

4.3.2.3. Les classificateurs de Bayes

Le classificateur de Bayes est un algorithme d'apprentissage probabiliste basé sur la théorie de Bayes qui donne des résultats performants même s'il y a peu de données [8]. Le théorème de Bayes indique comment prévoir la meilleure classe pour un exemple non résolu «e» de la base des exemples d'apprentissage : On choisit pour « e » la classe C_i qui maximise la probabilité suivante [8]:

$$P\left(\frac{C_i}{e}\right) = \frac{P(e/C_i)*P(C_i)}{P(e)} \quad (4.1)$$

Où $C_i \in \{\text{ensemble des classes possibles}\}$

$P\left(\frac{e}{C_i}\right)$ est estimée à partir du corpus d'apprentissage

4.3.2.4. Les réseaux de neurones

L'apprentissage neuronal a été utilisé avec efficacité dans les tâches de traitement du langage naturel. L'algorithme de Kohonen **LVQ** a été appliqué avec succès dans les tâches de catégorisation des textes. Cet algorithme d'apprentissage neuronal compétitif est encore un autre choix disponible. Un réseau de neurones (**RN**) est un réseau d'unités construit à partir des documents d'apprentissage, où les unités d'entrée représentent les termes, les unités de sortie représentent la (ou les) catégorie(s), et les arcs reliant les unités représentent les relations d'indépendances. Cette approche que nous allons la détailler après.

Quel que soit le type de la classification, on est confronté à différents problèmes. Dans le cas supervisé, un problème important peut-être le manque de données pour réaliser l'apprentissage ou la disponibilité de données inadéquates, par exemple incertaines et imprécises ce qui empêche la construction d'un modèle correct. Pour la classification non-supervisée, la délimitation des frontières entre les classes n'est pas toujours franche et

reconnaissable. Indépendamment du type de classification, les données multidimensionnelles, ou encore la dépendance des méthodes de classification aux paramètres initiaux comme le nombre de classes peuvent poser des problèmes. Afin de mesurer les performances des approches, on cherche à trouver des critères **Combinaison crédibiliste** de classification **supervisée** et **non-supervisée** sur la qualité des résultats. Généralement nous avons recours à des indices qu'on les appelle indices de validité. Il faut choisir l'indice le plus adéquat aux données ; il n'y a pas d'indice standard.

4.4. Les grandes familles des réseaux de neurones

Dans cette section, nous illustrons les familles des réseaux de neurones selon leurs dynamiques indépendamment des modèles de neurones artificiels.

4.4.1. Les réseaux feed-forward

Ce sont des réseaux dont la structure suit une logique de traitement de l'information au travers de couches de neurones successives, de l'entrée vers la sortie, sans retour de l'information en amont (voir [Fig.4.5](#)). C'est par exemple le cas des perceptrons et perceptrons multicouches [9]. Dans ces réseaux la dynamique est dirigée par la présentation des exemples d'entrée. Les activations se propagent en sens unique, de la couche d'entrée à la couche de sortie.




Fig.4.5- Structure d'un réseau feed-forward.

4.4.2. Les réseaux auto-organisés

Les cartes auto-organisatrices [10] sont inspirées de la structure du cortex, notamment visuel, dans lequel on peut observer une connectivité locale.

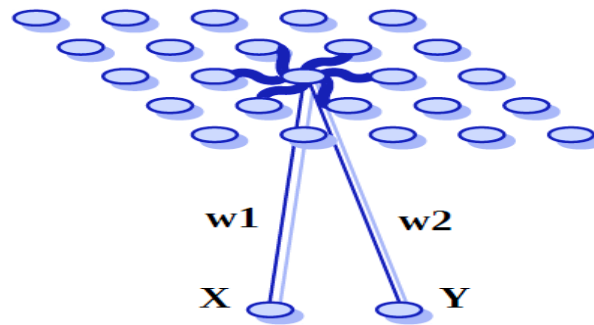


Fig.4.6- Modèle de Kohonen.

En d'autres termes, chaque neurone est connecté aux entrées et à ses voisins. Ce concept permet le traitement par un **RNA** d'informations dont on sait qu'elles portent des relations spatiales en elles, tels les pixels d'une image.

4.4.3. Les réseaux récurrents

Il s'agit de réseaux dont la structure, représentée sous forme de graphe, peut comporter des boucles. Ces boucles peuvent changer radicalement la dynamique qui pourra s'instaurer dans un RNA, et l'amener à s'auto-entretenir. La notion de réseau récurrent est étudiée et mise en application par Hopfield [11], dans une mémoire auto-associative, i.e. un réseau constitué d'une seule couche de neurones qui sont à la fois entrée et sortie. La récurrence se trouve dans le fait que les neurones sont tous interconnectés.

4.4.4. Les réseaux à résonance

Ces réseaux sont structurés de telle manière que l'activité de tous les neurones est envoyée à tous les autres neurones, provoquant ainsi des phénomènes de résonance et d'oscillation dans la dynamique du réseau. Parmi les représentants de cette famille, le modèle ART pour « Adaptive Resonance Theory » [12]. Les réseaux de Hopfield présentés dans les réseaux récurrents peuvent également avoir un fonctionnement en résonance. Ce principe est par exemple utilisé dans les modèles de mémoires associatives tels que les « Bi-directional Associative Memory » [13].

4.5. Propriétés des Réseaux de neurones artificiels

4.5.1. Apprentissage et mémoire

L'une des caractéristiques les plus importantes des réseaux de neurones artificiels est bien la capacité d'apprentissage. C'est une phase au bout de laquelle certaines modifications s'opèrent entre les connections des neurones : certaines sont renforcées et d'autres affaiblies ou

carrément inhibitrices. Le réseau converge alors vers un comportement souhaité. Ceci nous emmène à la notion de mémoire qui donne au réseau la capacité de retrouver des expériences passées ou des informations à partir d'éléments incomplets ou bruités (généralisation). Dans le paragraphe suivant, nous détaillerons d'avantage cette importante caractéristique des réseaux de neurones, plus connue comme **capacité de généralisation**. Le mécanisme de l'association permet aussi au réseau de converger vers un état à partir d'un autre état. Cette importante caractéristique est aussi connue sous le nom de mémoire adressée par le contenu, dont le modèle de Hopfield s'en inspire.

4.5.2. Sous-apprentissage, généralisation et sur-apprentissage

La capacité de généralisation est l'une des raisons qui motivent l'étude et le développement des réseaux de neurones artificiels. Elle peut être définie par la capacité d'élargir les connaissances acquises après apprentissage à des données nouvellement rencontrées par le réseau de neurones.

Cette capacité de généralisation est très liée à la notion de sur-apprentissage. Ces deux caractéristiques sont complètement antagonistes. On parle de sur-apprentissage quand le réseau a trop parfaitement appris les exemples proposés. Il sera donc incapable de se généraliser.

La figure (Fig.4.7) suivante illustre clairement ce compromis entre sur-apprentissage, sous-apprentissage et bonne généralisation.




Fig.4.7- Complexité d'apprentissage d'un réseau de neurones.

Afin d'arrêter l'apprentissage juste avant qu'il ne se produise ce phénomène de sur-apprentissage, plusieurs méthodes ont été proposées [14] :

La plus simple consiste à disposer de trois bases de données distinctes : une base d'apprentissage, une base de test est une base dite « validation croisée ». Cette dernière est utilisée pendant l'apprentissage afin d'examiner le comportement du réseau pour les données qui lui sont inconnues. Ainsi, l'apprentissage est arrêté lorsque l'erreur sur cette courbe (base de validation croisée) atteint un minimum.

4.6. Architectures neuronales les plus utilisées en diagnostic

Les techniques de diagnostic par réseaux de neurones sont fondées sur l'existence d'une base de données d'apprentissage et non sur l'existence d'un modèle formel ou fonctionnel de l'équipement. Le principe d'une telle application est de trouver une relation entre une (des) variable (s) d'entrée et une (des) variable (s) de sortie. Les variables d'entrée peuvent être quantifiables (sorties capteurs) ou qualifiables (observations faites par l'opérateur).

A partir de ces variables d'entrée, le réseau de neurones donne une réponse caractérisée par deux types de variables de sortie. Des variables de sortie réelles qui peuvent représenter une sortie estimée d'un paramètre de diagnostic ou des variables de sortie catégorielles qui représentent l'état de fonctionnement de l'équipement. Selon la nature de ces données en sortie, il existe deux types d'applications.

Le premier type est une application **d'approximation de fonctions**, qui consiste à estimer une sortie mesurée de l'équipement. Dans ce cas, les réseaux de neurones sont utilisés en tant qu'approximation universelle et fournissent un modèle sous la forme d'une boîte noire du système. Ceci n'est autre que de l'identification des processus industriels. Comme pour les méthodes à base de modèle, décrites au chapitre précédent, la comparaison de la sortie du réseau de neurones avec celle du système réel donne un résidu qui servira à déterminer si le système est dans un état défaillant ou pas.

Le deuxième type d'application considère le problème de diagnostic comme un problème de **reconnaissance des formes**. La forme à reconnaître est caractérisée par l'ensemble des données (quantifiables et / ou qualifiables) et les classes d'appartenance représentant les différents modes de fonctionnement ou de dysfonctionnement qui ont été définis au chapitre précédent. Le réseau de neurones doit nous fournir une réponse qui nous renseigne sur l'état de fonctionnement de l'équipement. La figure ci-dessous illustre les deux types d'applications des réseaux de neurones en diagnostic :

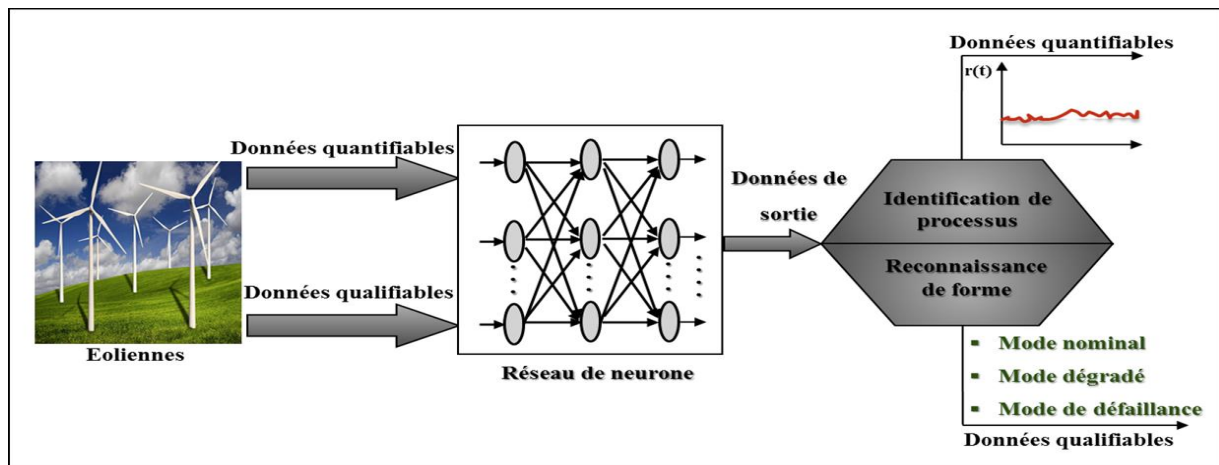


Fig.4.8- Application des réseaux de neurones en diagnostic d'équipement industriels.

Les types des réseaux de neurones les plus utilisés en diagnostic sont :

- Le perceptron Multi-Couches (PMC) ;
- Et avec un degré moindre les mémoires auto-associatives (modèle de Hopfield) et la carte de Kohonen ;
- Le Réseau à Fonctions de Bases Radiales (RBF).

Il faut savoir que chaque type de réseau de neurones a ses avantages et ses inconvénients selon l'application que l'on fait.

4.7. Réseau de neurones à Fonctions de bases Radiales (RBF)

La plupart des applications courantes utilisent une architecture du « réseau perceptron à couches multiples » dont la fonction d'activation à chaque nœud est de type sigmoïde [15]. Il existe un certain nombre de théorèmes garantissant les capacités d'approximations universelles dans certaines conditions (continuité de la fonction à approcher, nombre suffisant d'unités dans les couches cachées), même si le réseau ne comporte qu'une seule couche cachée.

Cependant, ces théorèmes ne fournissent pas des méthodes systématiques constructives guidant le choix de la topologie adapté pour une application particulière. En outre, ce type d'architecture entraîne des difficultés d'apprentissage dont les plus importantes sont :

- La présence de minima locaux dans la fonction de coût s'explique, par le fait que, les paramètres (poids des connexions) apparaissent non linéairement dans l'expression de la sortie du réseau. La permutation indifféremment des nœuds ainsi que leurs poids correspondants dans les couches cachées tout en gardant le même comportement de

sortie, augmente le nombre d'optima. Les méthodes d'ajustement de type « gradient » peuvent donc conduire à un apprentissage sous optimal, tandis que les méthodes à caractères stochastiques s'avèrent plus fiables mais plus pesantes ;

- La possibilité de paralysie durant l'apprentissage à cause de la saturation introduite par les sigmoïde ;
- La possibilité de désapprentissage dû au caractère « non local », introduit par la combinaison des sigmoïdes.
- La difficulté d'introduire l'information a priori, ce qui est dû au caractère distribué et non local de la représentation.

On peut, dès lors, songer à adapter un autre type d'architecture pour éviter au mieux ces problèmes.

Les réseaux de neurones à fonction de base radiale (RBF), surmontent toutes les difficultés d'apprentissage dans une architecture neuronale de type sigmoïde [15]. Cette variante de réseaux doit satisfaire les contraintes suivantes :

- Capacité d'approximation universelle ;
- Couverture mathématiquement exprimée, par le fait que, pour chaque sortie y_i associée à un vecteur d'entrée u , il existe au moins un paramètre w_j tel que la valeur $\left| \frac{\partial y_i(u, w)}{\partial w_j} \right|$ soit suffisamment grande au voisinage de u ;

- Généralisation locale : si la valeur $\left| \frac{\partial y_i(u, w)}{\partial w_j} \right|$ est grande au voisinage de u , elle doit être relativement proche de zéro une fois que l'on s'éloigne de ce voisinage.

Les réseaux de neurones à fonctions de bases radiales sont des réseaux de type **feed-forward** (réseaux à propagation avant) avec une seule couche cachée (**Fig.4.9**). L'utilisation de ces réseaux remonte aux années soixante-dix. Pour résoudre des problèmes d'interpolation multi-variables. Les bases théoriques de ces réseaux ont été ensuite approfondies et d'autres travaux se sont succédés où l'application des RBF a été élargie à d'autres domaines.

La particularité de ces réseaux réside dans le fait qu'ils sont capables de fournir une représentation locale de l'espace, grâce à des fonctions de base radiales $\rho(\|\cdot\|)$ dont l'influence est restreinte à une certaine zone de cet espace.

$\|\cdot\|$: représente la norme euclidienne.

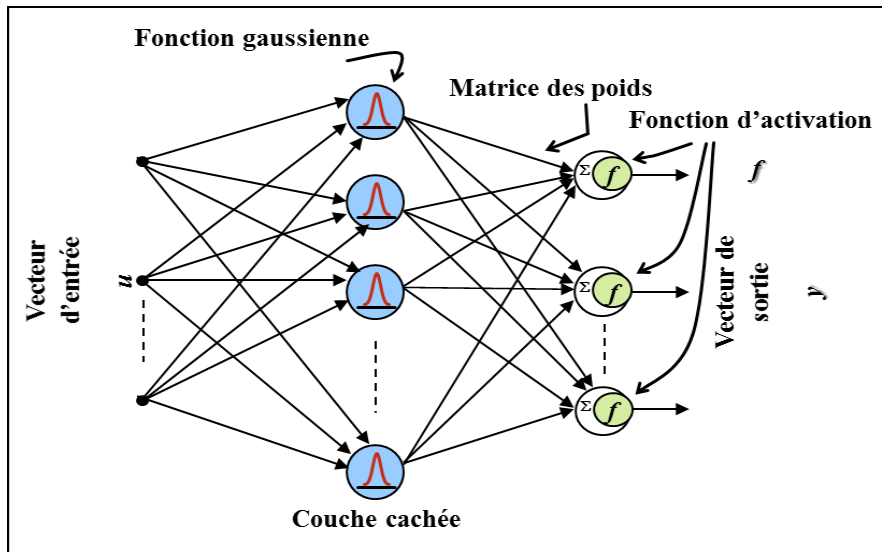


Fig.4.9- Réseau de neurones à fonction de base radiale.

La fonction de base radiale est sous la forme :

$$\rho_i(u) = \rho(\|u - c_i\|, \sigma_i) \tag{4.2}$$

Où deux paramètres sont associés à cette fonction :

- $\{c_i$: le vecteur de référence (centre ou prototype)
- $\{\sigma_i$: la dimension du champ d'influence (rayon d'influence)

La réponse de la fonction de base dépend donc de la distance du vecteur d'entrée u au vecteur prototype c_i , et de la taille du champ d'influence σ_i .

La fonction $\rho_i(u)$ est généralement maximale lorsque $(u = c_i)$ et décroît d'une façon monotone vers 0 quand $\|u - c_i\| \rightarrow \infty$.

La fonction de base la plus utilisée est la gaussienne. Elle s'exprime, sous sa forme la plus générale, par :

$$\rho_i(u) = \exp\left(-\frac{1}{2}(u - c_i)^T Q_i^{-1}(u - c_i)\right) \tag{4.3}$$

où c_i représente le vecteur du centre du nœud i , Q_i est la matrice des rayons gaussiennes, exprimée par l'équation suivante :

$$Q_j = \left(\text{diag}\left[\frac{1}{\sigma_{j1}} \frac{1}{\sigma_{j2}} \frac{1}{\sigma_{j3}} \dots \frac{1}{\sigma_{jn_e}}\right]\right)^2 \tag{4.4}$$

La décroissance de la gaussienne est la même pour toutes les directions de l'espace. Les courbes d'iso-activation des cellules cachées sont alors des hyper sphères. Un nombre restreint de fonctions de bases participent au calcul de la sortie pour une entrée donnée.

Les *RBF* peuvent être classés en deux catégories, en fonction du type du neurone de sortie :

1) **Normalisé :**

$$y(u) = \frac{\sum_j w_j \rho_j(u)}{\sum_j \rho_j(u)} \quad (4.5)$$

2) **Non-Normalisé :**

$$y(u) = \sum_j w_j \rho(u) \quad (4.6)$$

La raison essentielle du choix de la gaussienne comme fonction de base des *RBF* est que cette fonction peut être factorisée selon la formule suivante :

$$\rho(u) = e^{-\frac{\|u-\mu\|^2}{2\sigma^2}} = \prod_i e^{-\frac{(u_i-\mu_i)^2}{2\sigma^2}} \quad (4.7)$$

avec : $u = [u_i]$ et $\mu = [\mu_i]$; des vecteurs.




Fig.4.10- Factorisation d'un réseau à fonction de base radiale.

Cette particularité devient intéressante pour l'adéquation biologique des réseaux de neurones artificiels. On a du mal à imaginer comment un neurone est capable de calculer la fonction $\rho(u)$ pour des problèmes de grande dimension.

Par contre, le schéma de la figure (Fig.4.10) est biologiquement plausible. La fonction $\rho(u)$ a été factorisée en gaussiennes unidimensionnelles. Celles-ci représentent les fonctions d'activation des neurones.

Un deuxième avantage de la fonction de base en produit de gaussiennes unidimensionnelles est la possibilité d'avoir une matrice de variance complète. La décroissance des gaussiennes pour chaque dimension n'est donc pas forcément la même. Les cellules cachées sont alors des hyper ellipses (Fig.4.11). Ce type particulier de réseaux **RBF** s'appelle Réseaux de neurones à Fonctions de bases Radiales Généralisés (**RBFG**).

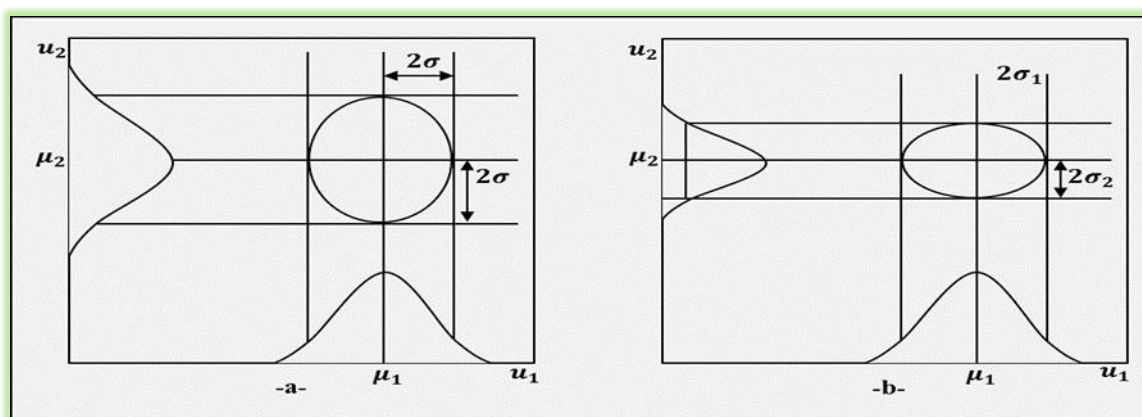


Fig.4.11- Intérêt de la factorisation de la fonction gaussienne.

- Fig4.11 -a- : matrice de variance-covariance diagonale (**RBF** sphérique) ;
- Fig4.11 -b- : matrice de variance-covariance complète (**RBF** Elliptique ou Généralisée).

La figure (Fig.4.12) suivante illustre l'avantage de la zone de couverture elliptique :

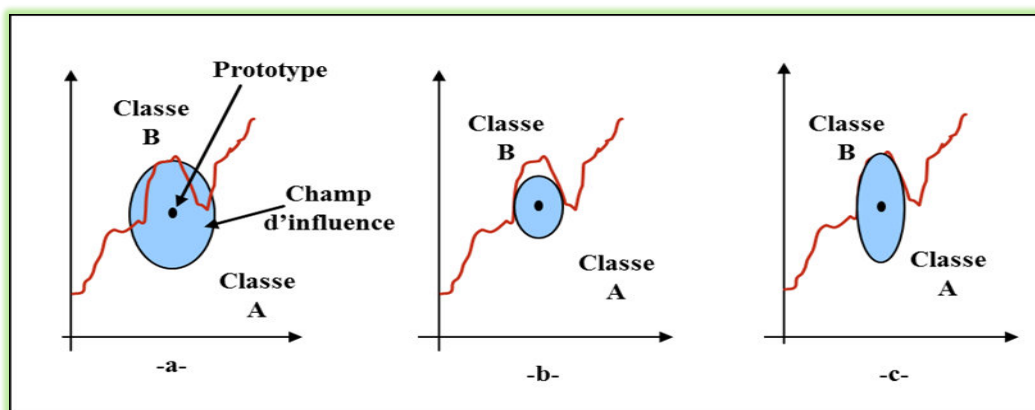


Fig.4.12- Avantage de la zone de couverture elliptique.

- -a- Sur-couverture du prototype ;
- -b- Sous-couverture du prototype ;
- -c- Couverture idéale.

Les centres d'un RBF sont choisis pour représenter les zones de grande concentration des données ou de les disposer en treillis réguliers pour couvrir uniformément la partie utile de l'espace d'entrée et respecter ainsi les contraintes de couverture et de généralisation localisée. La matrice de rayons est choisie le plus souvent diagonale.

Dans le cas où les centres sont disposés en treillis réguliers, c'est-à-dire la distance entre deux centres voisins est constante et les valeurs des rayons sont fixes, dans le but d'assurer un certain degré de recouvrement entre les différentes gaussiennes (le taux de recouvrement) exprimé par :

$$\tau = \exp\left(-\frac{1}{2}\left(\frac{\delta}{\sigma}\right)^2\right) \quad (4.8)$$

Le degré de recouvrement illustré par la figure 4.13 résulte d'un compromis entre les propriétés de localité et de généralisation, l'étendu de la généralisation est donc contrôlable.




Fig.4.13- Taux de recouvrement pour un treillis régulier unidimensionnel.

La plupart des applications utilisant les fonctions à bases radiales disposent des centres et des rayons fixés une fois pour toutes. Dans ce cas la sortie du réseau est linéaire en ces paramètres, il est tout à fait concevable d'utiliser les techniques d'optimisation linéaire classique pour obtenir un apprentissage rapide et précis. En outre, la disposition des centres a priori s'avère quelques fois impraticable. En effet, le nombre de centre requis est parfois trop élevé.

Le recours aux réseaux à bases radiales généralisés appelés aussi réseaux à bases radiales modifiés s'avère nécessaire. Ils permettent non seulement l'apprentissage des poids mais aussi celui des centres et des rayons.

Par conséquent, la sortie n'est plus linéaire avec les paramètres, cette caractéristique rend l'utilisation des algorithmes d'optimisation linéaire inutiles. L'ajustement effectué par une méthode de recherche locale, sur les poids, les positions des centres ainsi que les valeurs des rayons associés, risquent de tomber dans des minima locaux.

L'introduction des connaissances a priori sur la distribution initiale des centres, rayons et des poids permet de disposer des valeurs trop éloignées de celles optimales.

4.8. Extraction des paramètres de classification

L'extraction des caractéristiques est le processus consistant à rejeter les informations non pertinentes dans la mesure du possible et à représenter les données pertinentes sous une forme compacte et significative [16]. La fonction de distribution de probabilité est une caractéristique importante qui donne des informations significatives sur le domaine temporel concernant le signal. Tracer cela pour différentes classes de signal aidera à mettre en évidence leurs différences.

Afin d'obtenir de bonnes performances de diagnostic des pannes, dépend en grande partie de l'extraction des caractéristiques appropriées et des techniques de sélection des caractéristiques. La sélection des caractéristiques vitales ciblée est la principale contribution pour augmenter l'efficacité du processus de diagnostic des fautes.

4.8.1. Standard deviation

Mesurer la dispersion des ensembles de données à partir de sa moyenne. Plus la diffusion des données est importante, plus la déviation est élevée :

$$\bar{x} = \frac{1}{K} \sum_{k=1}^K x(k) \quad (4.9)$$

La moyenne et l'écart type peuvent être décrits comme :

$$std = \sqrt{\frac{\sum_{k=1}^K (x(k) - \bar{x})^2}{K-1}} \quad (4.10)$$

Si $x(k)$ est une série de signaux pour $k = 1, 2, \dots, K$ et k est le nombre de points de données.

4.8.2. Kurtosis

Les kurtosis sont des attributs statistiques d'ordre supérieur d'une série chronologique. Kurtosis mesure le pic de la fonction de densité de probabilité d'une série chronologique. Une valeur de kurtosis proche de trois indique un pic de Gauss. Les Kurtosis peuvent être utilisés pour identifier les pics majeurs dans les données et il utilise le quart normalisé du moment central :

$$kurtosis = \frac{\sum_{k=1}^K (x(k) - \bar{x})^4}{(K-1)std^4} \quad (4.11)$$

4.8.3. Central moment

Moment central de l'ordre trois d'une distribution qui est définie par :

$$m_k = E(x(k) - \bar{x})^k \quad (4.12)$$

4.8.4. Wavelet energy

Le concept d'énergie est lié aux notions habituelles dérivées de la théorie de Fourier. L'énergie d'un signal à chaque échelle sera :

$$E_i = \sum_k |C_j(k)|^2 \quad (4.13)$$

4.8.5. The total energy

Est obtenue par :

$$E_{tot} = \sum_{j < 0} E_j \quad (4.14)$$

4.8.6. Entropy

L'entropie de Shannon donne un critère utile pour analyser et comparer une distribution de probabilité. Il fournit une mesure d'information de n'importe quelle distribution, L'entropie d'ondelette est définie comme :

$$S_{WT} = S_{WT}(p) = - \sum_{j < 0} p_j \cdot \ln[p_j] \quad (4.15)$$

4.9. Décomposition du paquet d'ondelettes

Les ondelettes sont des fonctions mathématiques qui découpent les données en différentes composantes de fréquence. La transformée en ondelettes peut capturer plus d'informations localisées en temps et en fréquence qu'une transformée de Fourier. La transformée de paquets d'ondelettes est calculée en utilisant un filtrage de domaine temporel avec une représentation de sous-signal obtenue à partir des composantes de fréquence dans chaque sous-bande.

La méthode des paquets d'ondelettes est une généralisation de la décomposition en ondelettes qui offre une gamme plus riche de possibilités pour l'analyse des signaux et qui permet l'analyse la mieux adaptée à un signal. Il fournit une transformation niveau par niveau d'un signal du domaine temporel dans le domaine fréquentiel. Il est calculé à l'aide d'une récursivité d'opérations de décimation du filtre conduisant à la diminution de la résolution temporelle et à l'augmentation de la résolution en fréquence [17].

Les bandes de fréquences, contrairement à la transformée en ondelettes, sont de largeur égale, puisque le **WPT** (transformée en paquets d'ondelettes) divise non seulement la sous-bande basse, mais aussi la sous-bande haute fréquence.

Dans l'analyse par ondelettes, un signal est divisé en une approximation et un coefficient de détail. Le coefficient d'approximation est alors lui-même divisé en coefficients d'approximation de second niveau et en coefficients de détail, et le processus est répété.

Dans l'analyse de paquets d'ondelettes, les détails ainsi que les approximations peuvent être divisés. Cela donne différentes façons d'encoder le signal. Lorsque le **WT** est généralisé au **WPT**, non seulement la sortie du filtre passe-bas peut être itérée par un filtrage supplémentaire, mais le filtre passe-haut peut également être itéré. Cette capacité à réitérer les sorties du filtre passe-haut signifie que le **WPT** permet plus d'une fonction de base (ou paquet d'ondelettes) à une échelle donnée, par rapport au **WT** qui a une fonction de base à chaque échelle autre que le niveau le plus profond. L'ensemble des paquets d'ondelettes constitue collectivement la famille complète des bases possibles, et de nombreuses bases potentielles peuvent en être construites. Si seul le filtre passe-bas est itéré, le résultat est la base d'ondelettes. Si tous les filtres passe-bas et passe-haut sont itérés, la base de l'arbre complet est obtenue. Le niveau supérieur de l'arbre **WPD** est la représentation temporelle du signal [17].

Lorsque chaque niveau de l'arbre est traversé, il y a une augmentation du compromis entre la résolution temporelle et fréquentielle. Le niveau inférieur d'un arbre complètement décomposé est la représentation fréquentielle du signal. La figure (**Fig.4.14**) montre la décomposition de niveau 3 en utilisant la transformation de paquets d'ondelettes.

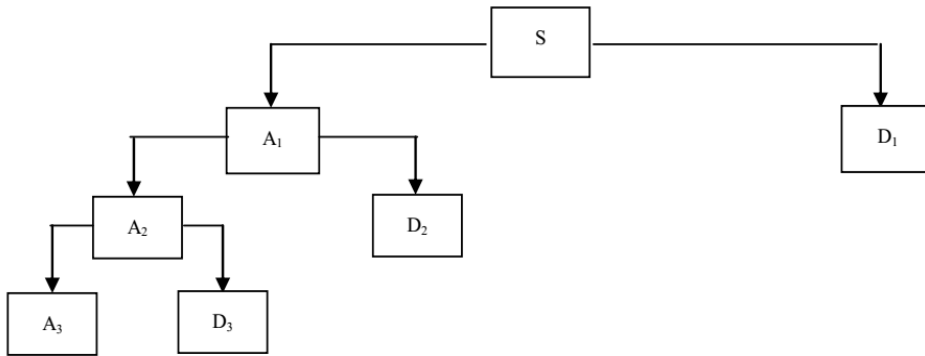


Fig.4.14- Décomposition niveau 3 avec la transformée en ondelettes.

La **DWT** fournit un moyen efficace d'examiner les caractéristiques d'un signal à différentes bandes de fréquences. Par conséquent, il est bien adapté aux outils de détection et de classification des défaillances dans le diagnostic des défauts de palier à roulement basé sur les signatures vibratoires des paliers. Le transformateur d'ondelettes discrètes **DWT** agit comme les bancs de filtres, qui utilisent des filtres passe-haut $h(k)$ et passe-bas $g(k)$. Les banques de filtres extraient du signal d'origine, la haute fréquence appelée (coefficients de détail) et basse fréquence appelée (coefficients d'approximation) comme suit :

$$d_{j+1}^{2p}(n) = d_j^p(n) * h(-2n), 0 \leq p < 2^j - 1 \tag{4.16}$$

Et

$$d_{j+1}^{2p+1}(n) = d_j^p(n) * g(-2n), 0 \leq p < 2^j - 1 \tag{4.17}$$

Où j : est l'échelle des ondelettes et n est le numéro de l'échantillon.

Dans chaque échelle, $h(k)$ et $g(k)$ filtrent les signatures de vibration de palier d'entrée de cette échelle, ce qui donne de nouveaux coefficients d'approximation et de détail, respectivement. Ainsi, ce processus divise le spectre de fréquence du signal original en bandes d'octave. De plus, le théorème de Nyquist stipule qu'un signal discret avec un taux d'échantillonnage de f_s a des composantes de fréquence limitées de 0 à $f = 2/2(j + 1)$. Par conséquent, le spectre de fréquence des coefficients de détail à l'échelle j est :

$$[f_s/2^{j+1}, f_s/2^j]$$

Par conséquent, la fréquence de sous-bande correspondante de détail et les coefficients d'approximation dans chaque niveau à deux échelles est représentée sur la figure (Fig.4.15).

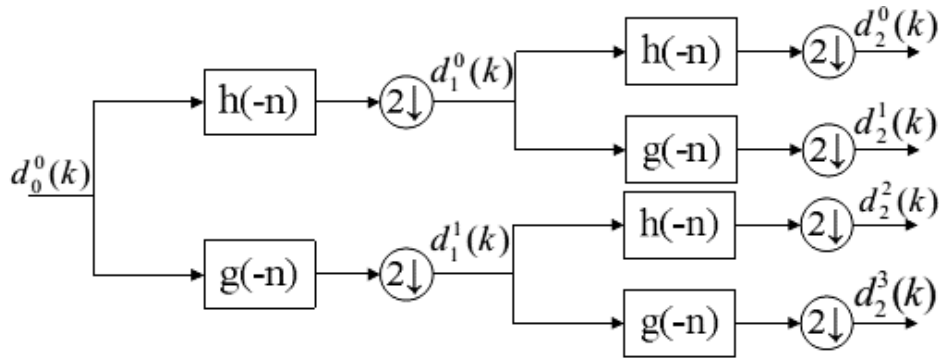


Fig.4.15- Décomposition de la banque de filtres de paquets d'ondelettes.

Le diagramme présenté sur la figure (Fig.4.16) présente les étapes suivies pour la classification des défauts en utilisant la transformée d'ondelettes niveau 1 pour calculer les coefficients de détails.

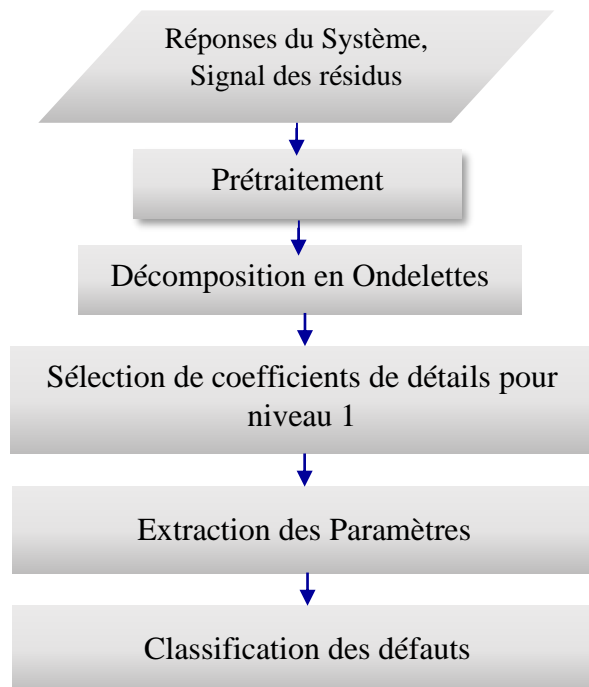


Fig.4.16- Les étapes à suivre pour la classification des défauts

4.10. Reconnaissance et Classification

Le théorème de Parseval est appliqué pour calculer l'énergie de déformation des paquets de détails que nous avons obtenus 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 déviation d'énergie peut être utilisée en entrée du schéma de classification à base d'un réseau de neurone type RBF selon l'organigramme de traitement suivant [18], [19] [20]:



Fig.4.17- Organigramme de traitement.

4.11. Distribution des niveaux d'énergies (Multi level Energy : ME)

La détection d'un mode de fonctionnement avec défaut est évaluée en utilisant la distribution des niveaux d'énergies calculée à partir des coefficients de détails. En appliquant le théorème de Parseval, on peut déterminer l'énergie des coefficients de détails $D1$, en utilisant une fenêtre de Hanning avec un décalage à travers le signal à chaque échantillon, selon l'expression suivante :

$$ME(k) = \sum_{n=k}^{k+N_w} r^2(n) \quad (4.18)$$

Avec N_w , la longueur de fenêtre.

4.12. Les résultats de simulations

Dans cette partie nous présentons les résultats de simulation de l'application de la détection et classification par réseaux de neurones sur les résultats obtenus de notre modèle de simulation.

Pour évaluer la performance de la technique proposée dans la pratique, les aspects suivants doivent être pris en compte :

- Collecte d'un ensemble de données de mesure dans différentes conditions de fonctionnement ;
- Sélection des paramètres statistiques de classification en utilisant une analyse temporelle et fréquentielle ;
- Introduction d'un classificateur basé sur la technique du réseau neuronal ;

Les mesures utilisées sont le couple électromagnétique, les vitesses d'entrée et de sortie du multiplicateur et la puissance mécanique, pour un mode de fonctionnement sain et défectueux avec différents niveaux d'altérations. Ces signaux sont utilisés pour réaliser une classe de données de références.

La simulation est composée de trois scénarios : cas sain, cas avec défauts paramètres électriques, et cas avec défauts de backlash. Les figures (**Fig.4.21** et **Fig.4.22**) présente les coefficients de détail dans le cas sain pour : C_e, Ω_1, Ω_2 et P_m . Dans le cas des défauts

électriques nous introduisons des incertitudes de 5% à 20%, les figures (Fig.4.23 à Fig.4.38) illustrent les erreurs et les coefficients de détail de : C_e , Ω_1 , Ω_2 et P_m pour le cas électrique. Pour le cas d'un défaut de backlash on fait varier j_0 pour différentes valeurs (0.1 à 0.4 rad). Les figures (Fig.4.39 à Fig.4.54) illustrent les erreurs et les coefficients de détail de : C_e , Ω_1 , Ω_2 et P_m .

Pour la détection des défauts, nous avons utilisé la fonction ME, comparée avec le niveau d'énergie pour un cas de fonctionnement sain. Pour le cas de fonctionnement en défaut, nous remarquons que les niveaux d'énergie deviennent de plus en plus importants. Cette augmentation des niveaux d'énergie est due à une fluctuation au niveau des grandeurs mesurées. Le choix de la fenêtre de décalage est justifié par un test de validation. La longueur N_ω est calculée en fonction de la vitesse de rotation ainsi que la fréquence d'échantillonnage. Les résultats de simulation obtenus montrent la variation du niveau d'énergie en fonction de l'amplitude du défaut. Le seuil de référence utilisé est calculé en fonction d'un niveau d'énergie correspondant un mode fonctionnement sain.




Fig.18- Evolution de l'erreur du couple électromagnétique (a) : Evolution Temporelle and (b) : Evolution de la fonction ME.




Fig.19- Evolution de l'erreur du Ω_1 : (a) : Evolution Temporelle and (b) : Evolution de la fonction ME




Fig.20- Evolution de l'erreur du Ω_2 : (a) : Evolution Temporelle and (b) : Evolution de la fonction ME

1- Cas-01 Mode de fonctionnement sain :




Fig.4.21- Coefficients de détail Pour Ce, Omega1 dans le cas Sain.




Fig. 4.22- Coefficients de détail Pour Omega2, Pm dans le cas Sain.

Les caractéristiques extraites du signal dans le cas sain sont indiquées dans le tableau 4.1.

Tableau 4.1 : Mode de fonctionnement sain :

Cas Sain avec des Incertitudes de 5%								
Param Grand	std	mad	μ^4	kurt	μ^6	μ^6 / std	Entropy	Energ_Tot
C_e	0.00037576	0.00010910	1.748616e-11	877.32560	5.062133e-15	1798229.430	0.0264453	7.8084169e-10
Ω_1	0.00060056	5.16614e-05	2.631192e-10	2023.1290	2.985689e-13	6363018.287	0.0149443	1.49122826e-09
Ω_2	0.00017398	7.47761e-06	2.713187e-12	2961.8133	3.282621e-16	11834496.665	0.0020484	1.20779699e-10
P_m	3.607735e-07	728.976275	2.6216172e-33	1188943.6	0	1.1771070e-15	.3877338e-07	11.23460145e-23

Les figures Fig.4.21 et Fig.4.22 illustrent les coefficients de détails **D1** calculés sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique. Les paramètres statistiques calculés à partir des coefficients de détails **D1**. Le résultat de calcul est illustré sur le tableau 4.1.

2- Défauts paramètres Electriques : dans cette catégorie des défauts, nous introduisons des défauts sur les paramètres électriques (R_s, L_s) au niveau de la génératrice asynchrone, selon les scénarios suivants :

- **Cas-01 : Coefficients de détails (D1) des différentes grandeurs (C_e, Ω_1, Ω_2 et P_m) avec défauts sur les paramètres électriques (R_s, L_s) de 5%.**




Fig. 4.23- L'erreur sur C_e et Ω_1 avec un défaut électrique sur les paramètres R_s et L_s de 5%.




Fig.4.24- L'erreur sur Omega2 et Pm avec un défaut électrique sur les paramètres Rs et Ls de 5%.





Fig.4.25- Coefficients de détail Pour Ce et Omega1 avec un défaut électrique Sur les paramètres Ls et Rs de 5%.

Detail Coefficient at level 01 of Omega2 with Electrical Parameters (Rs,Ls) fault at 5%



Detail Coefficient at level 01 of Pm with Electrical Parameters (Rs,Ls) fault at 5%




Fig.4.26- Coefficients de détail Pour Omega2 et Pm avec un défaut électrique Sur les paramètres Ls et Rs de 5%.

Tableau 4.2 : Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 5% :

Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 5%								
Param Grand	std	mad	μ^4	kurt	μ^6	μ^6/std	Entropy	Energ_Tot
C_e	0.00174069	0.00021389	8.153e-09	888.61	2.876e-11	1033905.03	0.1215292	1.67351e-08
Ω_1	0.0051808	0.00070248	5.898e-07	819.2411	1.887e-08	976271.37	0.0949242	1.28955e-07
Ω_2	0.0020117	0.0004339	1.038e-08	634.4387	4.377e-11	660316.56	0.08728	1.916454e-08
P_m	0.0266141	0.00515	0.000648	1293.21	0.000787	2214797.7	1.191605	3.18887e-06

Les figures (Fig.4.23 et Fig.4.24) illustrent l'erreur introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique. Ces erreurs sont calculées entre un mode de fonctionnement sain et un mode de fonctionnement défectueux avec une incertitude sur les paramètres électriques (R_s, L_s) d'ordre 5%. Nous pouvons remarquer clairement la dérive générée à cause de ce défaut. Pour extraire cette altération, nous avons utilisé la décomposition niveau 01 en ondelette (Fig.4.25 et Fig.4.26). Le calcul des paramètres statistiques est appliqué sur le coefficient de détail **D1**. Le résultat de calcul est

illustré sur le tableau 4.2. La sensibilité de ces paramètres par rapport à un cas sain est claire et se diffère d'un paramètre à un autre, ce qui nous permet par la suite de sélectionner que les paramètres discriminants.

- **Cas-02 : Coefficients de détails (D1) des différentes grandeurs (C_e , Ω_1 , Ω_2 et P_m) avec défauts sur les paramètres électriques (R_s , L_s) de 10%.**




Fig.4.27- L'erreur sur C_e , Ω_1 avec un défaut électrique sur les paramètres R_s et L_s de 10%.




Fig.4.28- L'erreur sur Omega2, Pm avec un défaut électrique sur les paramètres Rs et Ls de 10%.





Fig.4.29- Coefficients de détail Pour Ce, Omega1 avec un défaut électrique Sur les paramètres Ls et Rs de 10%.

Detail Coefficient at level 01 of Omega2 with Electrical Parameters (Rs,Ls) fault at 10%



Detail Coefficient at level 01 of Pm with Electrical Parameters (Rs,Ls) fault at 10%




Fig.4.30- Coefficients de détail Pour Omega2, Pm avec un défaut électrique Sur les paramètres Ls et Rs de 10%.

Tableau 4.3 : Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 10% :

Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 10%								
Param Grand	std	mad	μ^4	Kurt	μ^6	μ^6/std	Entropy	Energ_Tot
C_e	0.0021397	.0002844	1.94462 e-08	928.247	1.151e-10	1200083.37	2.6824e-08	1200083.37
Ω_1	0.00677	0.000836	1.7439e-06	830.533	9.451e-08	981400.16	2.2773e-07	981400.16
Ω_2	0.00314	0.0006	5.6658e-08	581.714	4.469e-10	464583.63	4.6262e-08	464583.63
P_m	0.0335138	0.0069184	0.0014519	1151.642	0.00263	1856393.24	1.3014858	5.1892e-06

Les figures (Fig.4.27 et Fig.4.28) illustrent l'erreur introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique avec une incertitude sur les paramètres électriques (R_s, L_s) d'ordre 10%. Les figures (Fig.4.29 et Fig.4.30) illustrent les coefficients de détails **D1** des différentes grandeurs. Le résultat de calcul des différents paramètres est illustré sur le tableau 4.3. La sensibilité de ces paramètres vis-à-vis le défaut ce genre d'altération est différente par rapport au cas précédent d'ordre 10%, ce qui justifié davantage le choix de ces paramètres.

- Cas-03 : Coefficients de détails (D1) des différentes grandeurs (C_e , Ω_1 , Ω_2 et P_m) avec défauts sur les paramètres électriques (R_s , L_s) de 15%.




Fig.4.31- L'erreur sur C_e , Ω_1 avec un défaut électrique sur les paramètres R_s et L_s de 15%.




Fig.4.32- L'erreur sur Ω_2 , P_m avec un défaut électrique sur les paramètres R_s et L_s de 15%.




Fig.4.33- Coefficients de détail Pour Ce, Omega1 avec un défaut électrique Sur les paramètres Ls et Rs de 15%.




Fig.4.34- Coefficients de détail Pour Omega2, Pm avec un défaut électrique Sur les paramètres Ls et Rs de 15%.

Tableau 4.4 : Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 15% :

Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 15%								
Param Grand	std	mad	μ^4	kurt	μ^6	μ^6/std	Entr	En_Tot
C_e	0.002262	0.0003031	2.56352e-08	978.836	1.846e-10	1376050.62	0.1509203	3.047e-08
Ω_1	0.008317	0.0010255	3.9595e-06	827.7046	3.316e-07	1001429.82	0.130084	3.4069e-07
Ω_2	0.003327	0.0006841	6.7549e-08	551.0599	6.094e-10	448603.09	0.2272027	5.3703e-08
P_m	0.041212	0.0080723	0.00346194	1200.82	0.009705	1980788.09	1.3677952	7.8057e-06

Les figures (Fig.4.31 et Fig.4.31) illustrent les erreurs introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique avec une incertitude sur les paramètres électriques (R_s, L_s) d'ordre 15%. Les figures (Fig.4.33 et Fig.4.34) illustrent les coefficients de détails D1 des différentes grandeurs. Le résultat de calcul des différents paramètres est illustré sur le tableau 4.4. Les mêmes remarques restent valables pour le cas d'altération de 15%.

- **Cas-04 : Coefficients de détails (D1) des différentes grandeurs (C_e, Ω_1, Ω_2 et P_m) avec défauts sur les paramètres électriques (R_s, L_s) de 20%.**




Fig.4.35- L'erreur sur C_e, Ω_1 avec un défaut électrique sur les paramètres R_s et L_s de 20%.




Fig.4.36- L'erreur sur Omega2, Pm avec un défaut électrique sur les paramètres Rs et Ls de 20%.





Fig.4.37- Coefficients de détail Pour Ce, Omega1 avec un défaut électrique Sur les paramètres Ls et Rs de 20%.

Detail Coefficient at level 01 of Omega2 with Electrical Parameters (Rs,Ls) fault at 20%



Detail Coefficient at level 01 of Pm with Electrical Parameters (Rs,Ls) fault at 20%




Fig.4.38- Coefficients de détail Pour Omega2, Pm avec un défaut électrique Sur les paramètres Ls et Rs de 20%.

Tableau 4.5 : Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 20% :

Défauts sur les Paramètres Electriques (R_s, L_s) avec une Erreur de l'ordre de 20%								
Param Grand	std	mad	μ^4	kurt	μ^6	μ^6/std	Entr	En_Tot
C_e	0.0023549	0.0004611	2.894e-08	941.589	2.2887e-10	1341869.16	0.1618537	3.32881e-08
Ω_1	0.0084432	0.0010246	4.301e-06	846.902	3.6891e-07	1018248.95	0.1288062	3.5089e-07
Ω_2	0.0040882	0.0007499	1.976e-07	708.111	3.4897e-09	747431.29	0.2457344	8.740559e-08
P_m	0.0436396	0.0087202	0.0035133	969.3195	0.0093297	1350772.78	1.3849164	9.053899e-06

Les figures (Fig.4.35 et Fig.4.36) illustrent les erreurs introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique avec une incertitude sur les paramètres électriques (R_s, L_s) d'ordre 20%. Les figures (Fig.4.37 et Fig.4.38) illustrent les coefficients de détails D1 des différentes grandeurs. Le résultat de calcul des différents paramètres est illustré sur le tableau 4.5. Les mêmes remarques restent valables dans un d'altération pour le scénario de 20%.

3- Défauts de Backlash : Pour le cas des défauts de backlash affectant le multiplicateur, nous introduisons des défauts sur le jeu d'engrenage j_0 , selon les scénarios suivants :

- **Cas-01 :** Coefficients de détails (D1) des différentes grandeurs (C_e , Ω_1 , Ω_2 et P_m) avec défauts de backlash d'amplitude $j_0=0.1$ rad .




Fig.4.39- L'erreur sur C_e et Ω_1 avec un défaut de Backlash $j_0=0.1$ rad.




Fig.4.40- L'erreur sur Ω_2 et P_m avec un défaut de Backlash $j_0=0.1$ rad.




Fig.4.41- Coefficients de détail Pour Ce et Omega1 avec un défaut de backlash $j_0=0.1$ rad.




Fig.4.42- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.1$ rad.

Tableau 4.6 : Défauts de backlash d'amplitude $J_0=0.1$ rad :

Défaut de backlash d'amplitude $J_0=0.1$ rad								
Param Grandeurs	std	mad	μ^4	kurt	μ^6	μ^6/std	Entr	En_Tot
C_e	0.0009449	7.9464e-05	1.5244e-09	1912.454	3.415e-12	4797062.66	0.031427	3.8356e-09
Ω_1	0.0010829	6.8715e-05	2.5093e-09	1825.222	8.930e-12	5537725.88	0.028724	4.8471e-09
Ω_2	0.000459	2.0428e-05	1.6559e-10	3729.960	1.7513e-13	18714153.34	0.012687	8.2314e-10
P_m	9.5823e-07	7.6812e-08	4.9255e-21	5843.629	2.9258e-29	37794060.31	0.00000	3.9732e-15

Les figures (Fig.4.39 et Fig.4.40) illustrent l'erreur introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique. Ces erreurs sont calculées entre un mode de fonctionnement sain et un mode de fonctionnement défectueux avec une amplitude de backlash d'ordre **0.1** rad. Nous pouvons remarquer clairement la dérive générée à cause de ce défaut. Pour extraire cette altération, nous avons utilisé la décomposition niveau 01 en ondelette (Fig.4.41 et Fig.4.42). Cette opération peut être considérée comme étant un traitement de débruitage. L'information pertinente est contenue dans la partie bruitée. Le calcul des paramètres statistiques est appliqué sur le coefficient de détail **D1**. Le résultat d calcul est illustré sur le tableau 4.6. La sensibilité de ces paramètres se diffère d'un paramètre à un autre, ce qui nous aide par la suite à sélectionner que les paramètres discriminants.

- **Cas-02 : Coefficients de détails (D1) des différentes grandeurs (C_e , Ω_1 , Ω_2 et P_m) avec défauts de backlash d'amplitude $j_0=0.2$ rad.**




Fig.4.43- L'erreur sur Ce et Omega1 avec un défaut de backlash $j_0=0.2$ rad.




Fig.4.44- L'erreur sur Omega2 et Pm avec un défaut de Backlash $j_0=0.2$ rad.




Fig.4.45- Coefficients de détail Pour Ce et Omega1 avec un défaut de backlash $j_0=0.2$ rad.





Fig.4.46- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.2$ rad.

Tableau 4.7 : Défauts de backlash d'amplitude $J_0=0.2 \text{ rad}$:

Défaut de backlash d'amplitude $J_0=0.2 \text{ rad}$								
Param	std	mad	μ^4	kurt	μ^6	μ^6/std	Entropy	En_Tot
Grand								
C_e	0.00091347	9.2301e-05	1.7929e-09	2575.7	5.8771e-12	10115425.56	0.033507	3.9150e-09
Ω_1	0.00307569	0.000159	2.4388e-07	2726.05	9.4516e-09	11164697.7	0.0353756	3.7529e-08
Ω_2	0.00115638	4.908e-05	6.8006e-09	3804.25	4.5987e-11	19232614.43	0.0179414	5.1983e-09
P_m	1.9263e-06	2.8217e-07	7.4171e-20	5388.32	1.7114e-27	33496539	0.000000	1.795e-14

Les figures (Fig.4.43 et Fig.4.44) illustrent l'erreur introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique avec une amplitude de backlash d'ordre **0.2 rad**. Les figures (Fig.4.45 et Fig.4.46) illustrent les coefficients de détails D1 des différentes grandeurs. Le résultat de calcul des différents paramètres est illustré sur le tableau 4.7. La sensibilité de ces paramètres vis-à-vis le défaut de backlash d'amplitude d'ordre **0.2 rad** est différente par rapport au cas précédent d'ordre **0.1 rad**, ce qui justifié davantage le choix de ces paramètres.

- Cas-03 : Coefficients de détails (D1) des différentes grandeurs (C_e , Ω_1 , Ω_2 et P_m) avec défauts de backlash d'amplitude $j_0=0.3 \text{ rad}$

Fig.4.47- L'erreur sur C_e et Ω_1 avec un défaut de backlash $j_0=0.3 \text{ rad}$.




Fig.4.48- L'erreur sur Omega2 et Pm avec un défaut de Backlash $j_0=0.3$ rad.




Fig.4.49- Coefficients de détail Pour Ce, Omega1 avec un défaut de backlash $j_0=0.3$ rad.

Detail Coefficient at level 01 of Omega2 Error with Backlash fault at Level $j_0=0.3$ rad




Fig.4.50- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.3$ rad.

Tableau 4.8 : Défauts de backlash d'amplitude $J_0=0.3$ rad :

Défaut de backlash d'amplitude $J_0=0.3$ rad								
Param Grand	std	mad	μ^4	kurt	μ^6	μ^6/std	Entr	En_Tot
C_e	0.001082	9.705e-05	3.1882e-09	2321	1.2561e-11	7799213.8	0.03882	4.9688e-09
Ω_1	0.006469	0.00029	5.8361e-06	3333.24	1.138e-06	15527007.9	0.0369851	1.63161e-07
Ω_2	0.002105	8.705e-05	7.5515e-08	3840.317	1.6969e-09	19453460.6	0.0203597	1.71965e-08
P_m	3.679e-05	8.194e-06	9.29199e-15	5070.53	7.62e-20	30703593.8	0.00197	2.55882e-12

Les figures (Fig.4.47 et Fig.4.48) illustrent l'erreur introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique avec une amplitude de backlash d'ordre 0.3 rad. Les figures (Fig.4.49 et Fig.4.50) illustrent les coefficients de détails D1 des différentes grandeurs. Le résultat de calcul des différents paramètres est illustré sur le tableau 4.8. Les mêmes remarques sont valables pour ce scénario de simulation.

- Cas-04 : Coefficients de détails (D1) des différentes grandeurs (C_e , Ω_1 , Ω_2 et P_m) avec défauts de backlash d'amplitude $j_0=0.4$ rad

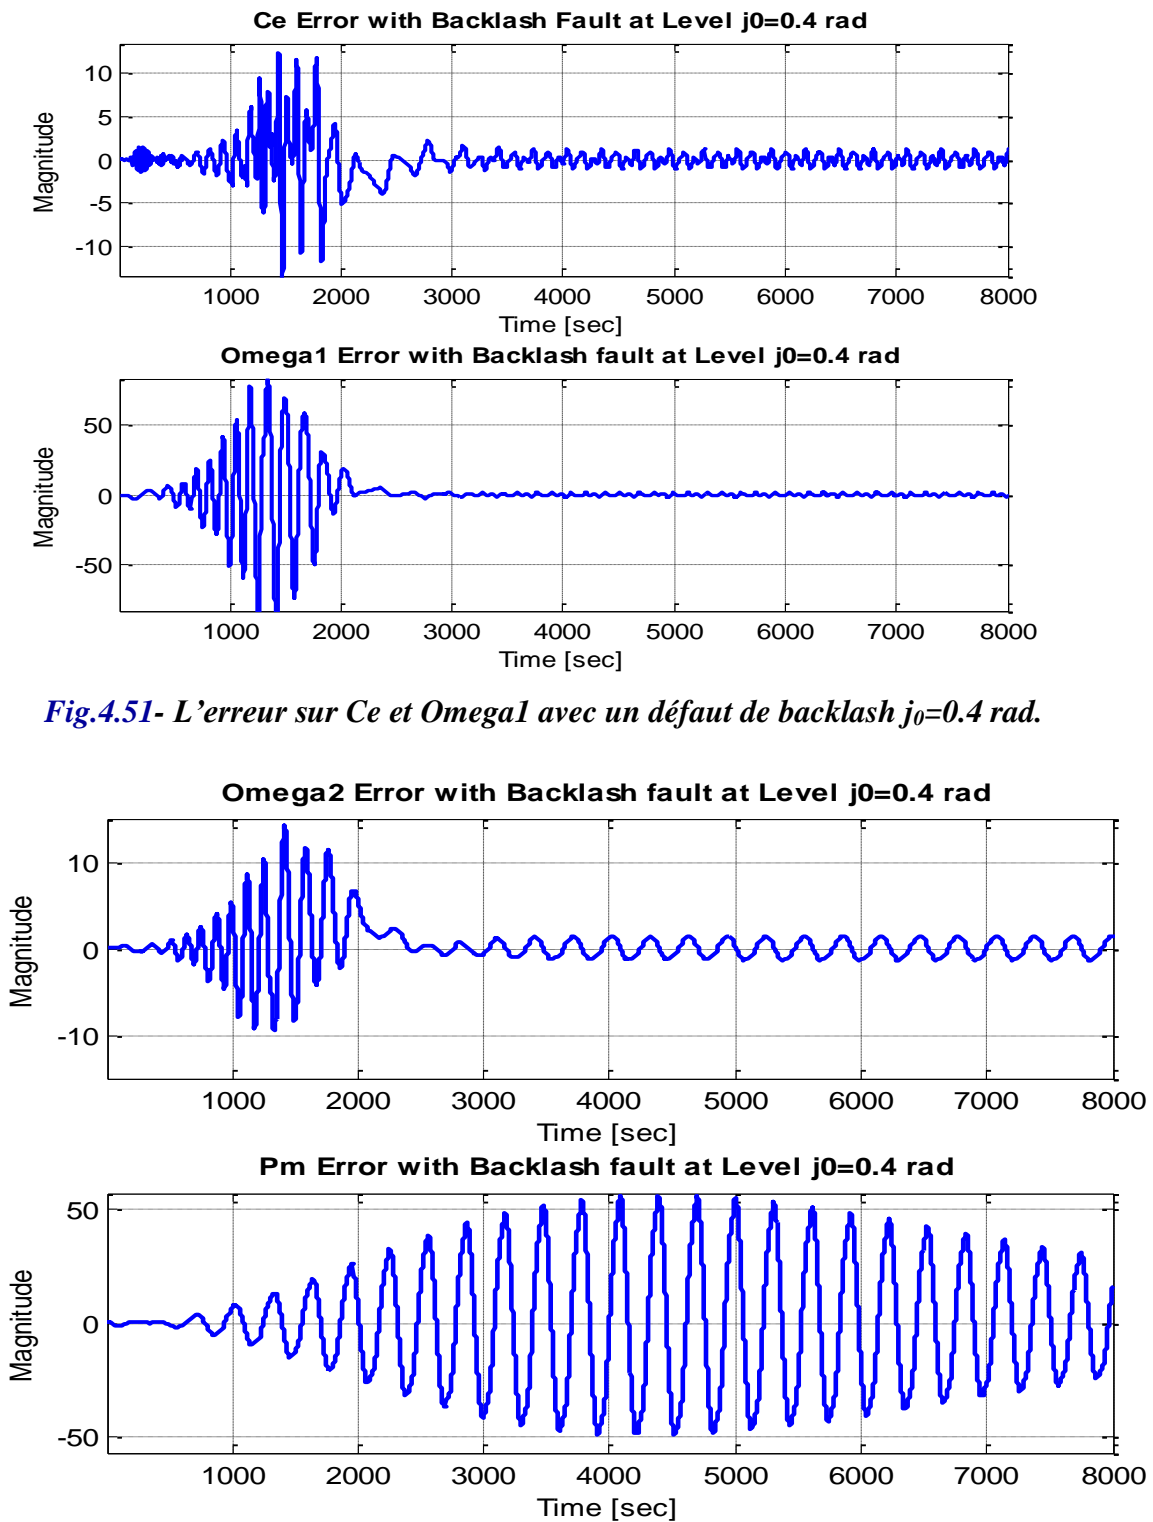


Fig.4.51- L'erreur sur C_e et Ω_1 avec un défaut de backlash $j_0=0.4$ rad.

Fig.4.52- L'erreur sur Ω_2 et P_m avec un défaut de Backlash $j_0=0.4$ rad.




Fig.4.53- Coefficients de détail Pour Ce, Omega1 avec un défaut de backlash $j_0=0.4$ rad.




Fig.4.54- Coefficients de détail Pour Omega2 et Pm avec un défaut de backlash $j_0=0.4$ rad.

Tableau 4.9 : Défauts de backlash d'amplitude $J_0=0.4$ rad :

Défaut de backlash d'amplitude $J_0=0.4$ rad								
Param	std	mad	μ^4	kurt	μ^6	μ^6/std	Entr	En_Tot
Grand								
C_e	0.00154745	0.000123	2.490e-08	4345.029	3.258e-10	23733606.69	0.04871644	9.50027e-09
Ω_1	0.0109900	0.00046414	5.196e-05	3563.237	3.037e-05	17241945.39	0.03840252	4.6863e-07
Ω_2	0.00323642	0.0001310	4.197e-07	3826.8029	2.216e-08	19287439.58	0.0237338	4.0591e-08
P_m	8.32159e-05	2.12667e-05	1.53e-13	3192.9666	5.089e-18	15326975.03	0.0019704	2.10558e-11

Les figures (Fig.4.51 et Fig.4.52) illustrent l'erreur introduites sur le couple électromagnétique, la vitesse de rotation lente, la vitesse de rotation rapide et la puissance mécanique avec une amplitude de backlash d'ordre 0.3 rad. Les figures (Fig.4.53 et Fig.4.54) illustrent les coefficients de détails **D1** des différentes grandeurs. Le résultat de calcul des différents paramètres est illustré sur le tableau 4.9. Les mêmes remarques sont valables pour ce scénario de simulation.

Discussion des résultats :

Les résultats obtenus lors de la simulation illustrent l'influence des défauts d'origine électrique et d'origine mécanique sur le bon fonctionnement du système éolien. Les deux origines de défauts sont à considérer comme étant des sources de pollution fréquentielle sur les différentes réponses du système éolien, ce qui est par la suite introduira une pollution électrique au niveau du réseau électrique. Pour bien illustrer cette influence, nous avons adopté une démarche selon les scénarios sus-indiqués. Les défauts électriques et mécaniques sont graduellement introduits. Il est clair que l'introduction de ce genre de défauts altère d'une manière significative le bon fonctionnement du système.

Pour classer ces défauts, un vecteur de caractéristiques est généré en utilisant des paramètres statistiques calculés à partir du niveau des coefficients de détail (**D1**). La sélection de ces paramètres est effectuée en utilisant les paramètres suivants : la fonction *std*, les moments centraux de la fonction *MAD*, l'énergie totale du signal, l'entropie et les valeurs de *Kurtosis*. Ces paramètres sont calculés à l'aide des coefficients de détail **DWT** au premier niveau de décomposition. D'après les résultats de simulation, nous pouvons remarquer clairement la sensibilité des différents paramètres vis-à-vis la gravité du défaut. Une base de données a été réalisée pour l'utiliser par la suite comme étant des entrées du réseau classifieur basé sur l'ANN.

La table.4.3 à la table 4.9, illustrent les paramètres de caractéristiques. Le résultat obtenu montre que la meilleure structure à utiliser est 10-10-10 : 4 figure (Fig.4.55). Les résultats de la classification des tests d'entraînement sur l'ensemble des signaux d'enregistrements étaient de 80%. Ces résultats montrent facilement que ces paramètres peuvent être utilisés comme indicateur d'état opérationnel pour discriminer entre un mode de bon fonctionnement par rapport à un mode défectueux.




Fig.4.55- La courbe de performance pour 10-10-10 :4

4.13. Conclusion

Dans ce chapitre, nous avons présenté d'une manière succincte, l'analyse spectrale basée sur les méthodes classiques et l'analyse multi-résolution basée sur les ondelettes. Cette alternative constitue une solution prometteuse pour extraire des primitives discriminantes qui seront utilisées par la suite pour l'analyse et le diagnostic de défauts des Backlash. Cette hypothèse est justifiée car nous considérons qu'un défaut est dans la majorité des cas est un phénomène de nature non stationnaire. Dans notre travail de recherche, nous avons utilisé la distribution des niveaux d'énergie calculés à partir des coefficients de détails (ME) pour évaluer la présence d'un défaut.

La procédure d'extraction de caractéristiques et les diverses caractéristiques extraites des signaux de défauts utilisant la transformée en ondelettes discrète (DWT) et la transformée de Fourier rapide (FFT) sont décrites dans cette section. Les caractéristiques extraites pour chacune des trois classes de défauts dans chacune des sous-bandes à quatre niveaux sont totalisées. La sélection des caractéristiques basées sur l'analyse des caractéristiques est

également clairement décrite. Enfin, les caractéristiques critiques qui donnent les meilleurs résultats de classification sont présentées.

Bibliographies

- [1] **G. Zwingelstein**, *Diagnostic des défaillances*, Paris: Hermès, 1995.
- [2] **R. Quinlan**, «*Induction of Decision Trees*,» *Machine Learning*, pp. 1, 81-106, 1986.
- [3] **R. Quinlan**, *Programs for machine learning, C4.5: Programs for machine learning*, 1993.
- [4] **V. Vapnik**, «*Support vector machines, reproducing kernel hilbert spaces and the gacv*,» 1998.
- [5] **T. Joachims**, «*Text Categorization with Support Vector Machines: Learning with Many Relevant Features*,» vol. 1398, n° 1137-142, 1998.
- [6] **R. Herbrich**, *Learning Kernel Classifiers: Theory and Algorithms*, School of Computer Science carnegie Melton University, 2001.
- [7] **E. Youn et M. K. Jeong**, *Class dependent feature scaling method using naive Bayes classifier for text datamining*, *Pattern Recognition Letters*, 2009.
- [8] **WEISSENBACHER et N. A.**, «*Identifier les pronoms anaphoriques et trouver leurs antécédents : l'intérêt de la classification bayésienne.*,» Juin 2007.
- [9] **D. E. Rumelhart et J. L. Mc Clelland**, «*Parallel Distributed Processing : Exploration in the MicroStructure of Cognition.*,» 1986.
- [10] **T. Kohonen**, «*Self-organized formation of topologically correct feature maps.*,» 1982.
- [11] **J. J. Hopfield**, «*Neural networks and physical systems with emergent collective computational abilities.*,» vol. 79 (8), n° 12554{2558., 1982.
- [12] **S. Grossberg**, «*Adaptive pattern classification and universal recoding, I: Parallel development and coding of neural feature detectors & II: Feedback, expectation, olfaction, and illusions.*,» vol. 23, n° 1121-134 & 187-202., 1976.
- [13] **Kosko**, «*Bidirectional Associative Memories*, *IEEE transaction on systems.*,» vol. 18, n° 11, 1988.
- [14] **Juan Manuel TORRES MORENO**, *Apprentissage et Généralisation des Réseaux de Neurones. Etude des nouveaux algorithmes Constructifs.*, Grenoble France., 1997.
- [15] **E. Viennet**, *Réseaux à fonctions de base radiales*, Lavoisier: Hermès, 2006.
- [16] **Y. U. Khan et O. Farooq**, «*Autoregressive features based classification for seizure detection using neural network in calp Electroencephalogram*,» vol. 2, n° 14, pp. 370-381, 2009.
- [17] **I. Daubechies**, «*Ten lectures on wavelets*,» SIAM, 1992.
- [18] **G. ZWE-LEE**, «*Wavelet-based neural network for power disturbance recognition and classification*,» vol. 19, 2004.
- [19] **S. y. lee**, «*Two dimensional, weighted PCA algorithm for face recognition*,» 2005.
- [20] **G. ZWE-LEE**, «*Wavelet-based neural network for power disturbance recognition and classification.*,» *IEEE, Power Delivery*, vol. 19, 2004.
- [21] **M. Bentoumi**, *Outils pour la détection et la classification Application au diagnostic de défauts de surface de rail*, Nancy I, 2006.

Conclusion Générale

Conclusion Générale

L'objectif de ce travail de thèse était la mise en œuvre d'une démarche d'analyse et de diagnostic pour un système de production d'énergie éolienne.

Pour mettre en œuvre ce travail de recherche, nous avons établi le plan d'exécution suivant :

Présentation d'une manière succincte d'un état de l'art sur les notions de base adoptées dans le domaine de surveillance et de diagnostic des systèmes mécatroniques.

Description de système de production de l'énergie éolienne à base d'une génératrice asynchrone modélisé par l'outil Bond Graph. durant cette partie, nous avons mis en œuvre un modèle Bond Graph sous le logiciel 20-Sim pour les différents éléments constituant le système éolien.

Notre intérêt est porté essentiellement sur le défaut de backlash est affectant le multiplicateur de vitesse. A cet effet nous avons réalisé des tests de simulation selon plusieurs scénarios en fonction de l'amplitude du défaut de backlash. Les réponses du système vis-à-vis ce défaut ont été examinées dans le domaine temporel et le domaine fréquentiel.

Pour l'évolution de l'influence de ce défaut mécanique sur la qualité de l'énergie produite, nous avons sélectionnés des méthodes d'analyse et de diagnostic qualitatives et quantitatives utilisant l'approche signal.

Une analyse profonde a été effectuée dans le domaine temporel et fréquentiel en vue d'extraire les paramètres pertinents pour un éventuel diagnostic et classification. Nous avons développé des méthodes d'analyse spectrale paramétrique et non paramétrique pour pouvoir discriminer l'état défectueux par rapport à un état sain.

Une étude de séparation autrement dit de décomposition de la partie bruitée par rapport à la partie basse fréquence a été effectuée en utilisant la DWT. Le niveau sélectionné de décomposition est arrêté au niveau de décomposition un (01).

Le choix est justifié par le fait que ce qui nous intéresse est la partie bruitée parce que nous estimons que ce défaut se manifeste au niveau des réponses du système éolien sous forme de fluctuation harmoniques. A cet effet, nous avons considéré les coefficients de détails comme étant porteurs d'informations. Les résultats de simulation ont prouvé l'efficacité des hypothèses prévues dans le cahier des charges. Une évaluation de l'énergie spectrale ainsi qu'une évolution multi niveau d'énergie est utilisée pour annoncer la présence d'un défaut en

Conclusion Générale

se basant sur une éventuelle comparaison par rapport à un seuil calculé durant un mode de fonctionnement sain et défectueux.

Une fois la phase d'analyse et de détection ont été réalisées, nous allons procéder à une étape d'identification, localisation et classification. Pour ce faire nous avons adopté un schéma de classification basé sur les réseaux de neurones type RBF.

Le vecteur des paramètres caractéristiques qui seront utilisés pour la classification sont calculé à base des paramètres statistique.

En fin une étude en simulation a été menée pour valider les modèles développés ainsi que leurs comportements vis-à-vis différents scénarios.

En résumé, ce modeste travail de recherche sur les systèmes mécatronique précisément le système d'éolienne, nous a permis d'avancer ce qui suit :

- Validation de l'efficacité de langage Bond graph pour la modélisation, Diagnostic et la génération des résidus ;
- L'efficacité et la robustesse de l'analyse spectrale paramétrique et non paramétrique pour l'estimation et l'analyse des défauts.

Suite à cette étude, quelques perspectives peuvent être faites :

- Construction d'une base de données contenant les différents défauts pouvant affecter un système éolien, en cite entre autres : défaut backlash, défaut d'orientation des pâles, défaut de génératrice, défaut de désalignement de l'arbre turbine ou génératrice...
- Développement des techniques de suppressions des vibrations dans les systèmes éoliens en utilisant les techniques de compensation des défauts de backlash.
- Mise en ouvre des méthodes de classification basée sur les algorithmes SVM, Boosting, QUEST, RANKBOOST, ID3, CART...
- Mise en œuvre d'un stand d'expérimentation émulant le fonctionnement d'un système éolien complet.