



N° d'ordre : . 02 / 2017

Autorisation de soutenance N° 36 /2017

THESE

Présentée pour l'obtention du grade de DOCTORAT 3^{ème} Cycle

En : Automatique Appliquée

Maintenance en Instrumentation Industrielle

Par : Mohamed BEN RAHMOUNE

Sujet

Diagnostic des défaillances d'une turbine à gaz à base des réseaux de neurones artificiels pour l'amélioration de leur système de détection des vibrations

Soutenue publiquement, le 15 / 11 /2017, devant le jury composé de :

Nom et Prénom	Grade	Etablissement de rattachement	Désignation
Mr Abdellah KOUZOU	MCA	Université de Djelfa	Président
Mr Ahmed HAFIFA	Professeur	Université de Djelfa	Directeur de thèse
Mr Mouloud GUEMANA	MCA	Université de Médéa	Co Directeur de thèse
Mr Kamal MOHAMMEDI	Professeur	Université de Boumerdès	Examineur
Mr Mourad BACHEN	MCA	Université de Médéa	Examineur
Mr Mohamed Mounir RAZAOUI	MCA	Université de Djelfa	Examineur

Dédicaces

Je dédie cette thèse à :

Mes très chers parents, pour leurs encouragements et pour m'avoir permis de réaliser mes études dans les meilleures conditions.

A Mes frères Tidjani, Youcef.

Ma chère sœur NAIMA et ses fils Akram et Djawad

A toute ma famille

A tous mes amis, et en particulier DEROUICHE Boubakeur et son fils Mohamed

Et à tous ceux que j'aime

Mohamed Ben Rahmoune

Djelfa 05 Juin 2017

Remerciements

Le présent travail de thèse de doctorat L.M.D a été effectué au sein du laboratoire d'Automatique Appliquée et Diagnostics Industriel (LAADI) à la faculté des sciences technologiques de l'université de Djelfa.

Je tiens à exprimer ma reconnaissance et mes remerciements à mes directeurs de thèse, Monsieur **Ahmed HAFIFA** et **Dr. Mouloud GUEMANA** pour la confiance qu'ils m'ont témoignée en m'offrant la possibilité de travailler avec eux, et j'exprime ma reconnaissance et mon respect le plus profond vis à vis leurs encadrement et leurs disponibilités durant ces années de thèse.

Tous mes remerciements également à Monsieur **Dr. Abdellah KOUZOU**, Maître de conférences à l'Université de Djelfa, pour avoir accepté d'examiner mon travail et présider le jury et pour toutes ses discussions, ses conseils et sa bonne humeur.

Aussi, j'exprime toute ma gratitude à Monsieur **Kamal MOHAMMEDI**, Professeur à l'Université de Boumerdèse et à Monsieur **Mourad BACHEN**, Maître de conférences à l'Université de Médéa et à Monsieur **Mohamed Mounir RAZAOUI**, Maître de conférences à l'Université de Djelfa, pour avoir accepté de prendre part au jury.

Enfin, je voudrais rendre hommage à tous ceux qui, plus ou moins récemment, de près ou de loin, à leur manière m'ont aidé à mener à bien cette thèse.

Mohamed Ben Rahmoune

Djelfa 05 Juin 2017

ملخص

تم تصميم العمل في هذه الأطروحة لتوفير الحماية وتدابير السلامة ضد ظواهر عدم الاستقرار من خلال تقييم السلوك الديناميكية العميقة التي أجريت على توربينة الغاز. من أجل توفير إستراتيجية تشخيصية فعالة لهذا النوع من الآلات الدوارة، من خلال اقتراح نظام إشراف و مراقبة يقوم على تطوير تقنيات الذكاء الاصطناعي "الشبكات العصبية الاصطناعية" الموصولة ببعضها البعض وفقا للتكوين المعتمد في توربينة الغاز المدروسة. النتائج التجريبية التي تم الحصول عليها مرضية وتوضح ميزة نهج الشبكات العصبية الاصطناعية لتطوير إستراتيجية تشخيصية خاصة بتوربينات الغاز التي تسمح بمراقبة الأعطاب الناجمة على الاهتزازات وتبين كفاءة الشبكات العصبية الاصطناعية كأدوات حاسوبية قوية جدا في نمذجة الأنظمة الديناميكية المعقدة.

Résumé

Ce travail de thèse est conçu pour fournir des mesures de protections et sécurités contre les phénomènes d'instabilité par l'évaluation du comportement dynamique approfondi réalisé sur une turbine à gaz, dans le but de fournir une stratégie de diagnostics efficace à ce type de machine tournante, et cela par la proposition d'un système de supervision basé sur le développement des outils des réseaux de neurones artificiels, connectés entre eux selon la configuration adoptée à la turbine à gaz étudiée. Les résultats expérimentaux obtenus sont satisfaisants et illustrent l'intérêt des l'approche des réseaux de neurones artificiels pour l'élaboration d'une telle stratégie de diagnostics propre aux turbines à gaz. Cette approche permet de mieux gérer les défaillances causées par les vibrations et montre l'efficacité des ces réseaux de neurones comme outils de calcul très puissants dans la modélisation des systèmes dynamiques complexes.

Abstract

This thesis work is designed to provide protection and safety measures against the phenomena of instability by the evaluation of the deep dynamic behavior carried out on a gas turbine. In order to provide an effective diagnostic strategy for this type of rotating machine, by proposing a supervision system based on the development of artificial neural network tools, connected to each other according to the configuration adopted at the gas turbine studied. The experimental results obtained are satisfactory and illustrate the advantage of the approach of artificial neural networks for the development of a gas turbine-specific diagnostic strategy. This approach makes it possible to better manage the failures caused by the vibrations and showing the efficiencies of artificial neural networks as very powerful computational tools in the modeling of complex dynamic systems.

TABLE DES MATIÈRES

Liste des Figures	D
Liste des Tableaux	E
Liste des Travaux	F
Introduction Générale	01
CHAPITRE I: Etat de l'art sur les systèmes de diagnostic	04
I.1. Introduction	05
I.2. Définitions et terminologie	05
I.3. Caractéristiques d'un système de diagnostic	06
I.4. Phases de diagnostic	08
I.5. Résidus	10
I.5.1. Approche par espace de parité	11
I.5.2. Estimation paramétriques	13
I.5.3. Approche à base d'observateurs	14
I.6. Différentes types de défauts	16
I.6.1. Défaut avec changement brusque de mode	16
I.6.2. Dérive lente de défaut	16
I.7. Classification des méthodes de diagnostic	17
I.7.1. Méthodes internes de diagnostic.....	18
I.7.2. Approche externes de diagnostic	19
I.7.3. Approche utilisant le mode de raisonnement.....	19
I.8. Approches de diagnostic industriel	21
I.8.1. Méthodes d'analyse fonctionnelle	21
I.8.2. Méthodes d'analyse dysfonctionnelle	21
I.8.3. Méthodes déductives	21
I.8.4. Méthodes inductives	22
I.9. Redondances	22
I.9.1. Modélisation physique	22
I.9.2. Redondance analytique	23
I.10. Méthodes de diagnostic par analyse des signatures externes.....	24
I.10.1. Reconnaissance des formes.....	24

I.10.2. Systèmes experts de diagnostic	25
I.11. Diagnostic à base de la logique floue	25
I.12. Diagnostic à base des réseaux de neurones.....	26
I.13. Conclusion	28
CHAPITRE II: Approche de Réseaux de neurones artificiels Réseaux	29
II.1. Introduction.....	30
II.2. Réseaux de neurones artificiels.....	30
II.3. Fonctionnement d'un neurone formel	32
II.4. Model mathématique d'un neurone artificiel.....	32
II.5. Classification et propriétés des neurones artificiels	36
II.6. Architecture des réseaux de neurones.....	36
II.7. Apprentissage des réseaux de neurones.....	41
II.7.1. Apprentissage supervisé	43
II.7.2. Apprentissage auto organisation.....	43
II.7.3. Apprentissage par renforcement (semi – supervisé)	44
II.7.4. Règles d'apprentissage.....	44
II.7.5. Algorithme de la rétro-propagation du gradient (RPG)	47
II.8. Conclusion	51
CHAPITRE III: Détection des vibrations des turbines à gaz	52
III.1. Introduction.....	53
III.2. Turbines à gaz	54
III.3. Vibrations d'une turbine à gaz.....	54
III.3.1. Modélisation de vibrations de turbine à gaz.....	55
III.3.2. Vibrations des paliers de turbine	56
III.3.3. Défauts de désalignement	57
III.3.4. Phénomène de balourds.....	58
III.4. Danger et remèdes de vibrations des turbines.	58
III.5. Surveillance de vibrations	59
III.5.1. Indicateurs de surveillance de vibrations.....	60
III.5.2. Système de supervision à base d'intelligence artificielle	61
III.6. Supervision par réseaux de neurones artificiels	61
III.7. Résultats d'investigation des réseaux de neurones pour la détection de vibrations	62

III.7.1. Choix du modèle neuronal.....	64
III.8. Conclusion.....	76
CHAPITRE IV: Surveillance des défaillances d'une turbine à gaz à base des réseaux de neurones	
artificiels.....	77
IV.1. Introduction.....	78
IV.2. Turbine à gaz	78
IV.3. Modélisation de dynamique turbine à gaz GE MS 3002.....	81
IV.4. Surveillance de défaillance d'une turbine à gaz de type GE MS 3002.....	83
IV.5. Résultats d'application de procédure de surveillance de turbine GE MS 3002.....	90
IV.6. Contrôle de vitesse de la turbine haute pression	95
IV.7. Résultats d'applications de contrôle de la vitesse HP de la turbine	99
IV.8. Conclusion.....	113
Conclusion générale	114
Références Bibliographiques	116

Liste des Figures

Figure I.1 : Diagnostic à base de modèle.....	06
Figure I.2 : Dérive de capteur.....	07
Figure I.3 : Biais de capteur.....	07
Figure I.4 : Valeur aberrante.....	08
Figure I.5 : Défauts d'un processus physique	08
Figure I.6. Différentes phases du diagnostic industriel	10
Figure I.7 : Génération de résidus	11
Figure I.8 : Approche de l'espace de parité dans un format entrée / sortie	11
Figure I.9 : Approche d'estimation paramétrique	13
Figure I.10: Nature des défauts	17
Figure I.11: Classification des méthodes de diagnostic	18
Figure I.12: Diagnostic à base de modèle	18
Figure I.13: Méthodes internes de diagnostic	19
Figure I.14 : Procédure orientée mauvais fonctionnement (MF)	20
Figure I.15: Procédure orientée de bon fonctionnement (BF)	20
Figure I.16: Principe des méthodes basées sur la redondance analytique	23
Figure I.17: Procédure de diagnostic basée sur la reconnaissance des formes	24
Figure I.18 : Structure d'un système experts	25
Figure I.19: Structure d'un réseau neurone feed-forward	26
Figure II.1: Neurone biologique	31
Figure II.2: Fonctionnement d'un neurone	32
Figure II.3: Modèle non-linéaire d'un neurone formel	33
Figure II.4: Fonction caractéristique d'un réseau de neurone	34
Figure II.5: Quelques types des fonctions d'activations	35
Figure II.6 : Perceptron Multicouche PMC à trois couches	36
Figure II.7: Réseau monocouche	37
Figure II.8: Réseau multicouche	38
Figure II.9: Réseaux à fonction radiale (RBF)	39
Figure II.10: Réseaux de neurone dynamique avec deux couches	40
Figure II.11 : Couche de Kohonen avec deux intrants	41
Figure II.12: Apprentissage supervisé	43

Figure II.13: Apprentissage auto organisation	44
Figure III.1 : Amortissement et raideurs de palier	56
Figure III.2.A : Mode axiale	57
Figure III.2.B : Mode angulaire	57
Figure III.2.C : Mode radiale	57
Figure III.3 : Force centrifuge due au Balourd	57
Figure III.4: Endommagement du démarreur pneumatique de la turbine à gaz	59
Figure III.5 : Organigramme de supervision de vibrations de la turbine	60
Figure III.6: Système supervision de turbine à gaz	63
Figure III.7: Schéma général de la modélisation	64
Figure III.8 – III.31: Résultats de d'application	65-75
Figure IV.1 : Turbine à gaz TMS3002	79
Figure V.2. Turbine à gaz à deux arbres	80
Figure VI.3. Usure des ailettes du compresseur axial	81
Figure IV.4. Fonctionnement d'un neurone artificiel	84
Figure IV.5: Analyse d'indicateurs de défauts	86
Figure VI.6. Fonction d'activation de type sigmoïde	87
Figure VI.7. Fonction d'activation de type linéaire	87
Figure VI.8. Autorégressive non linéaire dynamique avec entrée exogène externe (NARX)	89
Figure VI.9 – VI.36 : Résultats de d'application	91-112

Liste des tableaux

Tableau II.1 : Fonctions d'activation comparées au seuil θ	31
Tableau II.2 : Règle de Hebb.....	45
Tableau VI.1. Caractéristiques techniques de la turbine à gaz MS 3002.....	79
Tableau VI.2. Performances du Modèle NARX de la vanne de commande d'air IGV.....	94
Tableau VI.3. Performance du Modèle NARX de la vanne de contrôle de gaz CGV.....	94
Tableau VI.4. Performances du Modèle NARX de l'arbre de la turbine à haute pression HP.....	94
Table VI.5. Performances du Model NARX.....	94

Liste des Travaux

Publications

- [1]. **Ben Rahmoune Mohamed**, Ahmed Hafaifa and Guemana Mouloud, Vibration modeling improves pipeline performance, costs. Oil & Gas Journal, Mars 2015, pp. 98-100. URL: <http://www.ogj.com/articles/print/volume-113/issue-3.html>
- [2]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa, Kouzou Abdellah and XiaoQi Chen, Monitoring of high-speed shaft of gas turbine using artificial neural networks: Predictive model application. DIAGNOSTYKA the Journal of Polish Society of Technical Diagnostics (PSTD), 2016, vol. 18, no. 4, pp.... (Accepted paper) URL: <http://diagnostyka.net.pl/archive/view-articles/diagnostyka-vol-18-no-4-2017>
- [3]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa, Mouloud Guemana, Fault Diagnosis in Gas Turbine Based on Neural Networks: Vibrations Speed Application. Book Chapter in Advances in Acoustics and Vibration, Volume 5 of the series Applied Condition Monitoring pp 1-11, on line. 02 September 2016, ISBN: 978-3-319-41458-4, 2017. URL: http://link.springer.com/chapter/10.1007/978-3-319-41459-1_1
- [4]. Mouloud Guemana, Ahmed Hafaifa and **Mohamed Ben Rahmoune**, Reliability study of gas turbines for improving their availability by ensuring optimal exploitation. OIL GAS European Magazine, June 2015, vol. 2, pp. 88-91. URL: <http://oilgaspublisher.de/en/periodicals/>
- [5]. Fatima Bekaddour, **Mohamed Ben Rahmoune**, Chikhi Salim and Ahmed Hafaifa, Performance study of different metaheuristics for diabetes diagnosis. Book Chapter, Advances in Computational Intelligence, 2017, **SCOPUS** DOI: 10.1007/978-3-319-59153-7_51 URL: https://link.springer.com/chapter/10.1007/978-3-319-59153-7_51

Conférences Internationales

- [1]. Fatima Bekaddour, **Mohamed Ben Rahmoune**, Chikhi Salim and Ahmed Hafaifa, Performances study of different metaheuristics algorithm for diabetes diagnosis. International Work-Conference on Artificial Neural Networks IWANN 2017, 14-16 June, 2017, Cadiz, Spain. URL: <http://iwann.uma.es/>
- [2]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa, Mouloud Guemana and Nadji Hadroug, Elaboration of fault tree for gas turbine application based on an expert system using artificial neural networks. The International Conference on Technological Advances in Electrical Engineering ICTAEE'16, 24-26 October 2016, Skikda, Algeria. URL: <http://ftech.univ-skikda.dz/ictaee/>
- [3]. **Ben Rahmoune Mohamed**, Ahmed Hafaifa, Kouzou Abdellah, Control and diagnostic of vibration in gas turbine system using neural network approach. The 8th International Conference on Modelling, Identification and Control, ICMIC 2016, 15-17 November 2016, Algiers, Algeria. URL: <http://www.icmic2016.org/>
- [4]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa, Mouloud Guemana, Fault diagnosis in gas turbine based on neural networks: Vibrations speed application. Proceedings of the International Conference on Acoustics and Vibration ATAVI'16, March 21-23, 2016, Hammamet -Tunisia. URL: <http://www.atavi.org/ICAV2016/>
- [5]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa and Guemana Mouloud, Étude la fiabilité d'une turbine à gaz pour l'amélioration de leur disponibilité. The 1st International Conference on Applied Automation and Industrial Diagnostics (ICAAID 2015), Djelfa on 29-30 March 2015, Algeria. URL: <http://www.univ-djelfa.dz/icaaid/>
- [6]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa and Guemana Mouloud, Gas turbine supervision based on neural networks in degraded mode: Presence of vibrations. The 1st International Conference on Applied Automation and Industrial Diagnostics (ICAAID 2015), Djelfa on 29-30 March 2015, Algeria. URL: <http://www.univ-djelfa.dz/icaaid/>
- [7]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa and Mouloud Guemana, Elaboration of a faults tree in gas turbine using expert system based on neural network. INTERNATIONAL CONFERENCE ON ENERGY SYSTEMS ISTANBUL 2015 - ICES2015, 23-25 December 2015, Istanbul-Turkey. URL: <http://www.ices2015conference.com/>

- [8]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa and Mouloud Guemana, Neural network monitoring system used for the frequency vibration prediction in gas turbine. The 3rd International Conference on Control, Engineering & Information Technology CEIT'2015, on 25-27 May 2015 Tlemcen, Algeria. URL: <http://ieeexplore.ieee.org/search/searchresult.jsp?newsearch=true&queryText=Mohamed%20Bn%20Rahmoune>
- [9]. Mouloud Guemana, Ahmed Hafaifa and **Ben Rahmoune Mohamed**, Reliability modelling using Rayleigh distribution: Industrial pump application. Proceedings of the 19th European Conference on Mathematics for Industry ECMI2016, 13-17th June 2016, Santiago de Compostela, Spain. URL: <http://www.usc.es/congresos/ecmi2016/>
- [10]. Ahmed Zohair Djeddi, Ahmed Hafaifa, **Ben Rahmoune Mohamed**, Abudura Salam and Mouloud Guemana, Reliability estimation in industrial process using Log-normal distribution: Gas turbine application. INTERNATIONAL CONFERENCE ON ENERGY SYSTEMS ISTANBUL 2015 - ICES2015, 23-25 December 2015, Istanbul-Turkey. URL: <http://www.ices2015conference.com/>
- [11]. **Mohamed Ben Rahmoune**, Ahmed Hafaifa and Mouloud Guemana, Vibration monitoring in gas turbine speed using artificial neural networks. The 3rd International Conference on Information Processing and Electrical Engineering (ICIPEE'14), TEBESSA on 24-25 November 2014, Algeria. URL: <http://www.univ-tebessa.dz/fr/ICIPEE2014>

Conférences Nationale

- [1] **Ben Rahmoune Mohamed**, Ahmed Hafaifa and Mouloud Goumana, Maintenance prédictive d'une turbine à gaz basé sur l'analyse de fiabilité et de disponibilité. 5ème Symposium de l'Association Algérienne de l'Industrie du Gaz AIG Sonatrach, 16-17 Février 2016, Alger. URL: <http://aig.dz/programme-du-5eme-symposium/>

Introduction générale

Le transport du gaz naturel en milieu des hydrocarbures requiert des équipements très complexes, répartis sur plusieurs stations de compressions du gaz sur le long du gazoduc, afin de distribuer le gaz aux différents utilisateurs. Les machines qui se sont avérées les plus indiquées sont les turbines à gaz. Néanmoins, ces machines sont soumises à un problème très important à savoir le phénomène de vibration, qui est un état d'instabilité de fonctionnement entraînant des pulsations pouvant être dangereuses pour leur tenue mécanique provoquant la dégradation de cette dernière conduisant à la rupture des ailettes suite à l'inversion du débit. Donc, il est essentiel de maintenir le fonctionnement de ces turbines en dehors de la zone d'instabilité. Pour prévenir ce phénomène, les turbines à gaz sont dotées de systèmes de surveillance qui permettent le contrôle en permanence le fonctionnement de ces machines. En effet, les solutions proposées jusqu'à présent pour prévenir ce phénomène n'ont pas donné des résultats encourageants, car ces systèmes présentent toujours un risque de passage en phase vibratoire. Face à ce problème rencontré en sûreté de fonctionnement des turbines à gaz, plusieurs développements ont été déployés par plusieurs applications industrielles, utilisant les techniques d'intelligence artificielle pour l'aide à la décision dans les systèmes de diagnostic et de surveillances. Parmi ces techniques, les réseaux de neurones artificiels réputés par leurs capacités et rapidité de modélisation, ils ont connu un grand succès pour résoudre des problèmes non linéaires dans l'industrie. Les réseaux de neurones artificiels permettent de traiter de multiples manières l'information et de mieux comprendre les rythmes de fonctionnement dans plusieurs systèmes industriels.

Des travaux ont été réalisés et se sont imposés par l'intérêt soutenu des réseaux de neurones artificiels pour plusieurs investigations sur les machines tournantes, bien que d'autres nombreux travaux ont été réalisés sur d'autres applications industrielles pour la modélisation et la commande de processus ou pour les sciences de traitement de l'information, pour résoudre les problèmes reconnus comme difficiles tels que l'optimisation, la classification, la reconnaissance des formes, le diagnostic et la prise de décision.

Nous proposons dans ce travail de thèse une approche de diagnostic des défaillances d'une turbine à gaz basée sur les réseaux de neurones artificiels pour l'amélioration de leur disponibilité. Cela nous permettra de développer une méthode originale pour maintenir et surveiller les turbines à gaz, en cas de défaillance ou d'accident de prévenir en temps réel.

Nous étudierons dans ce travail de thèse l'apport des techniques basés les réseaux de neurones artificiels à ces différents systèmes de supervision, on propose d'élaborer un classificateur neuronal – le plus performant que possible – permet de générer des indicateurs des défauts, afin de détecter, localiser et caractériser les défauts de vibration en degré de sévérités et en amplitude. Cela est dans le but de développer une méthode originale d'estimation des défauts de vibration et de déterminer ses gravités une chose n'est possible qu'avec une bonne stratégie de surveillance.

Pour mettre au point une telle procédure de supervision, basée sur les réseaux de neurones artificiels, ce travail propose alors une stratégie de diagnostic pour la détection des dysfonctionnements d'une turbine à gaz de type GE MS 3002, basée sur une modélisation autorégressive non linéaire dynamique avec entrée exogène externe (NARX).

Cette thèse est composée de quatre chapitres organisés de la façon suivante :

Le premier chapitre est consacré à un état de l'art sur les méthodes de diagnostic de défauts, pour les processus industriels. Nous présenterons les méthodes à base de modèle ainsi que les différents modes de représentations des systèmes sous forme de modèle. Différentes méthodes propres au diagnostic de défauts seront exposées dont l'objectif est de consulter toutes les caractéristiques ainsi que les avantages et les inconvénients de ces méthodes. Nous présentons en particulier les définitions de base et plus particulièrement les méthodes de génération de résidus fondées sur des modèles exacts. Nous caractériserons ensuite la qualité de ces méthodes par des critères de robustesse et de validation. Enfin, nous étudierons l'apport des techniques de réseaux de neurones artificiels à ces différents systèmes de diagnostic. Cela nous permettra de développer à la dernière partie du travail une méthode de diagnostic basée sur les réseaux de neurones artificiels pour la détection et la localisation des défauts de vibrations d'une turbine à gaz.

Dans **le deuxième chapitre**, nous présenterons le concept de base des techniques de réseaux de neurones artificielles dans un but de fournir des modèles fiables pour pouvoir prendre mesures de protection et de sécurité contre les phénomènes d'instabilité et cela par l'évaluation du comportement dynamique approfondi réalisés sur une turbine à gaz. En effet, le choix d'un modèle fiable de représentation des systèmes industriels souvent indispensable peut mener à bien des tâches de commande ou de diagnostic de ces systèmes. Pour cette raison, les approches à base de techniques d'intelligence artificielles constituent aujourd'hui un outil très puissant et de base pour l'aide à la décision, essentiellement pour réaliser des prédictions ou de modèles de simulation des processus à commander, ainsi que celles de modèles diagnostic et qui peuvent être obtenues soit à partir de

données réelles venant directement des variables de système à surveiller, soit à partir de données traitées venant des sorties de traitements de ces modèles.

Le troisième chapitre a pour objectif d'illustrer les différentes images sur les vibrations d'une turbine à gaz dans le cadre de la modélisation de ce phénomène en utilisant les techniques de réseaux de neurones artificiels. Notre travail est orienté dans ce sens pour déterminer et montrer comment dans une politique de maintenance, les vibrations sont mesurées, traitées, surveillées et servent pour un diagnostic, afin d'apprécier l'état mécanique de la turbine à gaz examinée. Car, la maîtrise des vibrations des machines tournantes reste toujours un défi industriel pour les entreprises possédants ce type de machines. Dans le cas des turbines à gaz, la déformation dynamique non maîtrisée d'une structure des boucliers et les ailettes peut entraîner un vieillissement prématuré des composants, ou encore des nuisances sonores et vibratoires inacceptables.

Dans le but d'étudier le comportement dynamique des turbines à gaz installées dans les unités de transport du gaz qui est dépend des règles et des plans de surveillances très sophistiqués. **Le quatrième chapitre** sera consacré à mettre en place notre approche de surveillance des défaillances de ces dernières à base des réseaux de neurones artificiels. La finalité et le but est de contribuer à l'élaboration de synthèse de ce système dans le diagnostic des défauts de ces turbines. Le système de surveillance des défaillances développé dans ce travail est donc basé sur une approche prédictive pour le contrôle de la vitesse de l'arbre de turbine à haute pression. Cela, nous a permis de faire une modélisation fiable de la dynamique de la turbine à gaz GE MS 3002 examinée, et a permis ainsi la détection et l'isolation des défauts de vibrations affectent cette turbine à gaz.

Nous terminons ce travail par des conclusions des perspectives de recherches associées

CHAPITRE I

ETAT DE L'ART SUR LES SYSTEMES DE DIAGNOSTIC

Cette partie de thèse sera consacrée à un état de l'art sur les méthodes de diagnostic de défauts pour les processus industriels. Nous présenterons des méthodes de base de modèle ainsi que les différents modes de représentations des systèmes sous forme de modèle. Différentes méthodes propres au diagnostic de défauts seront exposées. Nous présentons en particulier les définitions de base des méthodes de génération de résidus fondées sur des modèles exacts. Nous caractériserons ensuite la qualité de ces méthodes par des critères de robustesse et de validation. Enfin, nous étudierons l'apport des techniques de réseaux de neurones artificiels à ces différents systèmes de diagnostic. Cela nous permettra de développer à la dernière partie du travail une méthode de diagnostic basée sur les réseaux de neurones artificiels pour la détection et la localisation des défauts de vibrations d'une turbine à gaz objet d'étude dans ce présent travail.

I.1. Introduction

L'identification des défaillances dans les processus industriels par des stratégies de diagnostic, est toujours un sujet d'actualité très important dans le domaine de l'automatique moderne. Cependant, dans plusieurs travaux de recherches industrielles ont été réalisés dans ce domaine pour des finalités économiques posées par l'amélioration des performances de qualité, de disponibilité et de sûreté de fonctionnement et de fiabilité de ces systèmes. En vue de remplir ces objectifs de qualité, de sécurité et de disponibilité des systèmes technologiques, on leur affecte des stratégies de diagnostic servant à identifier tout écart de fonctionnement par rapport au fonctionnement désiré et même dans les situations de reconfiguration de la commande de système.

Cette partie de travail sera consacrée à un état de l'art sur les techniques de diagnostic de défauts, pour les systèmes industriels, où nous exposerons des approches à base de modèle ainsi que les différentes formes d'identification des systèmes avec des modèles analytiques. Pour ce faire, nous présenterons dans ce qui suit les concepts de certains principaux aspects de système de diagnostic, dont le but est de consulter toutes les performances en termes d'avantages et inconvénients de ces méthodes.

I.2. Définitions et terminologie

I.2.1. Détection et isolation des défauts

Le diagnostic s'inscrit en réalité industrielle dans une action de maintenance désignée à une partie de système de surveillance, il s'effectue en réalisant trois tâches bien distinctes; l'identification de défauts, la localisation et l'isolation des défauts [47], comme il est montré sur la Figure I.1.

I.2.1.1. Détection de défauts

La détection c'est l'action de détermination des dysfonctionnements dans le processus industriel, permet de voir l'occurrence d'un défaut et leur temps d'apparition, en utilisant un modèle de dysfonctionnement, elle identifie clairement le défaut. La détection vérifiée le dépassement d'un seuil du résidu et si le vecteur est nul en fonctionnement normale du système.

L'étape de détection est réalisée par l'utilisation d'un seuillage ou des tests statistiques.

- probabilité de fausse détection : conduit à des arrêts ou des reconfigurations inutiles,
- probabilité de non-détection : peut conduire à une panne, intolérable dans les systèmes à haut niveau de sécurité (aéronautique, nucléaire...).

1.2.1.2. Localisation de défauts

La localisation permet de localiser l'origine de panne lorsqu'un défaut a été détecté et permet la détermination de la classe à laquelle appartient le défaut, d'où l'isolation est consacré à décider quelle partie de processus est défectueux. Elle est suivie par la procédure d'isolation des défauts, c'est-à-dire sert à isoler une panne particulière.

1.2.1.3. Identification de défauts

L'identification de défauts conduit à déterminer l'instant d'apparition de panne, sa période et son amplitude permettent la détermination de toutes les informations analytiques sur l'apparition de ce défaut.

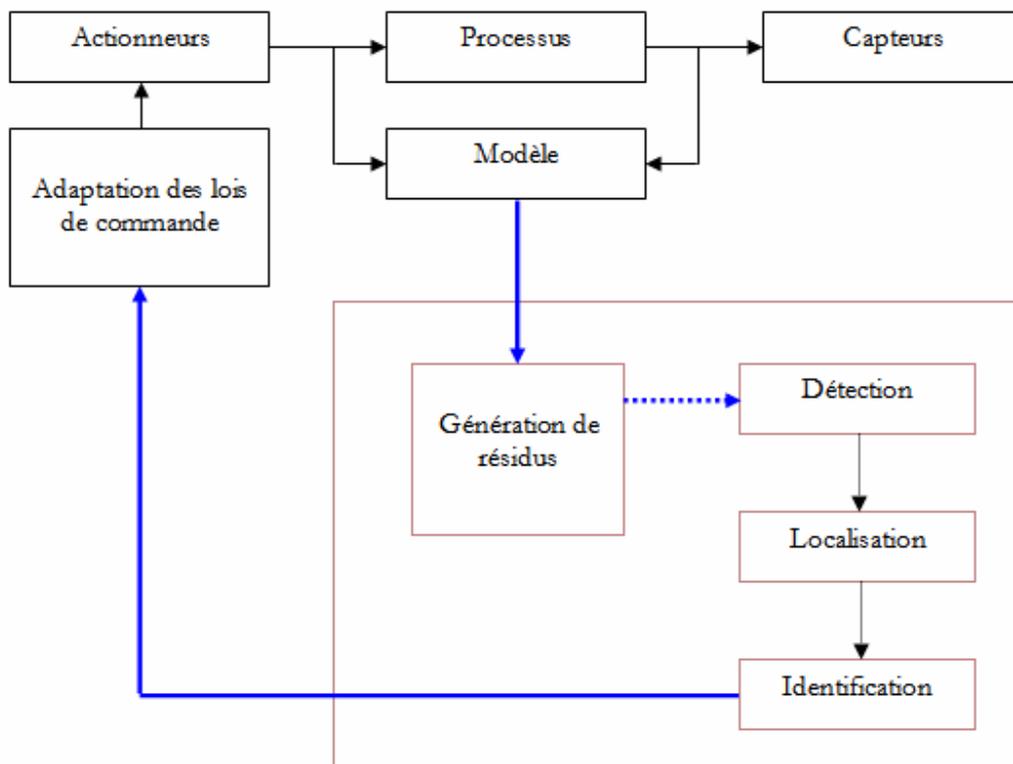


Figure I.1 : Diagnostic à base de modèle

1.3. Caractéristiques d'un système de diagnostic

D'une manière pratique, le diagnostic des processus industriels a pour objectif de l'identification et la localisation des défaillances du système à partir de l'étude de leurs effets par des tests, interventions, ou

par expériences passives sur le système. Dans le monde industriel, le diagnostic joue un rôle plus important d'après son efficacité à détecter les défauts apparus.

Un fois l'action de défaut est faite, on doit trouver la procédure de détection et l'isolation connu par les méthodes **FDI** (Fault Detection and Isolation) qui conduit à avoir des informations sur le degré et la provenance des défauts dans un temps optimale.

Pratiquement, les caractéristiques d'un système de diagnostic sont en fonction de trois fonctions; Les dérives, les valeurs aberrantes et les biais, , comme il est montré sur les Figures I.2, I.3 et I.4.

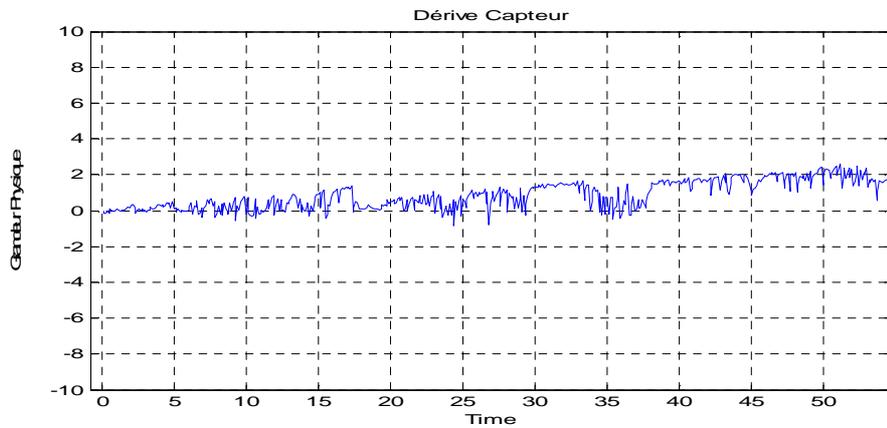


Figure I.2 : Dérive de capteur

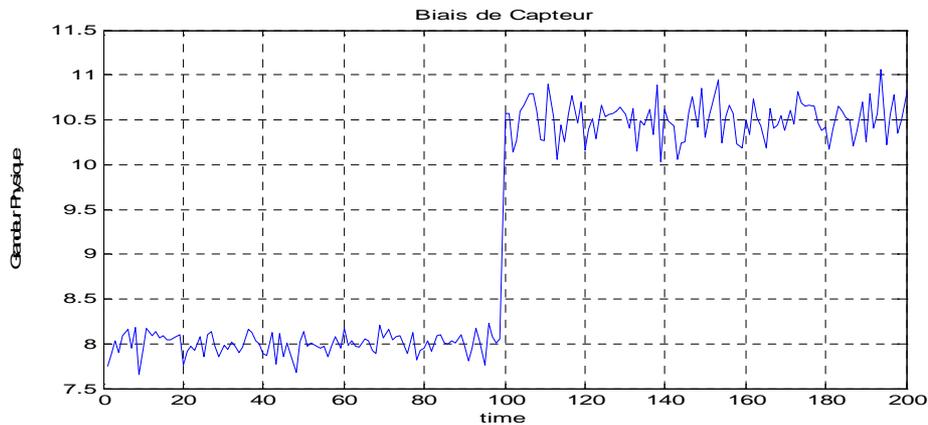


Figure I.3 : Biais de capteur

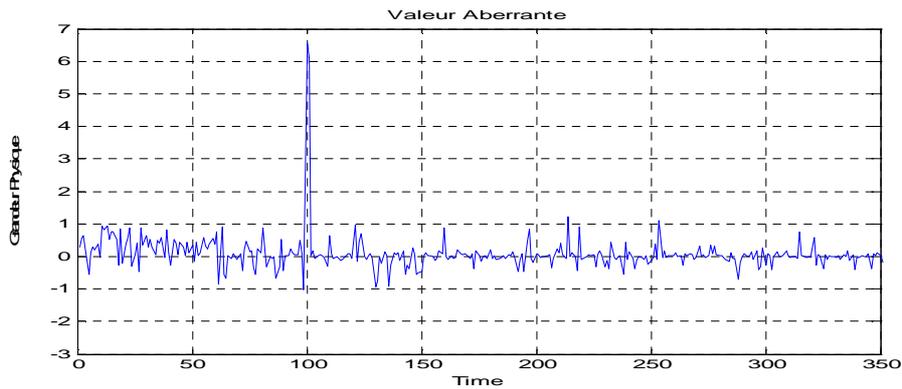


Figure I.4 : Valeur aberrante

Comme étant présenté dans la Figure I.5, ces trois fonctions de défauts peuvent affecter la globalité des éléments d'un système industriel. L'apparition d'un défaut inhérent aux organes de capteurs, aux mécanismes de contrôle donné par les actionneurs, où aux éléments de système lui même, ils se traduisent par des modifications du signal associé.

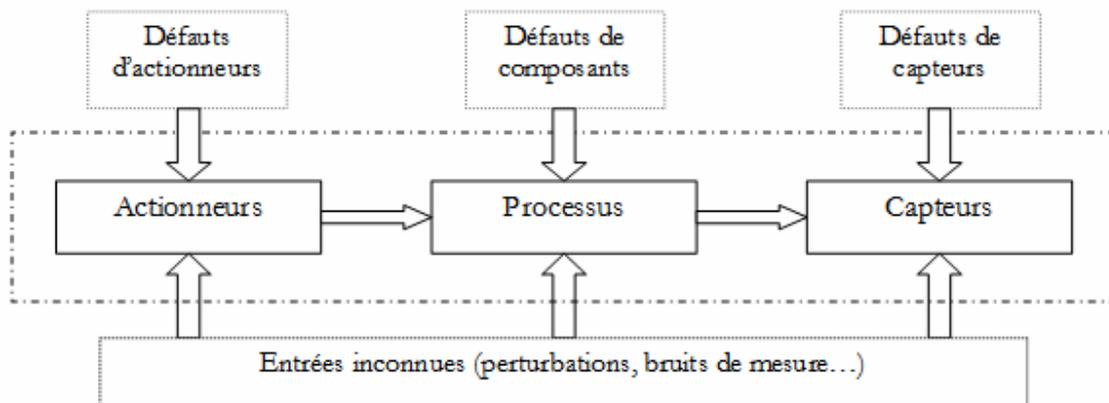


Figure I.5 : Défauts d'un processus physique

I.4. Phases de diagnostic

Le choix d'une stratégie de diagnostic la plus adéquate à un système industriel ne peut se faire qu'après un regroupement de toutes les informations nécessaires pour leur exploitation. Pratiquement cette fonction est composée de trois étapes; Détection, localisation et la décision où ce choix est dépend de [9] :

- Nature des causes de défaillances à localiser,
- Connaissance des symptômes associés aux défaillances induites par les causes,

- Maîtrise des moyens de mesure des symptômes,
- Maîtrise des moyens de traitement des symptômes,
- Connaissance des mécanismes physiques entre les causes et les effets,
- Inventaire du retour d'expérience,
- Recensement des expertises disponibles,
- Définition du niveau de confiance dans le diagnostic,
- Identification des utilisateurs finals du diagnostic.

I.4.1. Décisions en diagnostic

Le fonctionnement incorrect du système étant constaté, il s'agit de faire une action pour décider la façon à suivre afin de garder les performances désirées du système sous surveillé. Ces actions peuvent être l'ajustement des paramétrique de la loi de contrôle de point de consigne afin de compenser l'effet d'un défaut, une procédure normale d'arrêt ou encore un arrêt d'urgence en cas de détection d'une anomalie sévère mettent en danger les personnes ou le matériel. Plusieurs outils peuvent être utilisés :

- Classification et reconnaissance des formes,
- Utilisation d'arbres logiques,
- Systèmes experts ...

La Figure I.6 représente l'ensemble des tâches à réaliser pour assurer un fonctionnement satisfaisant d'un processus industriel. Le flux d'information traversant ces différentes phases subit des transformations au niveau de chaque étape, jusqu'à la prise de la décision finale.

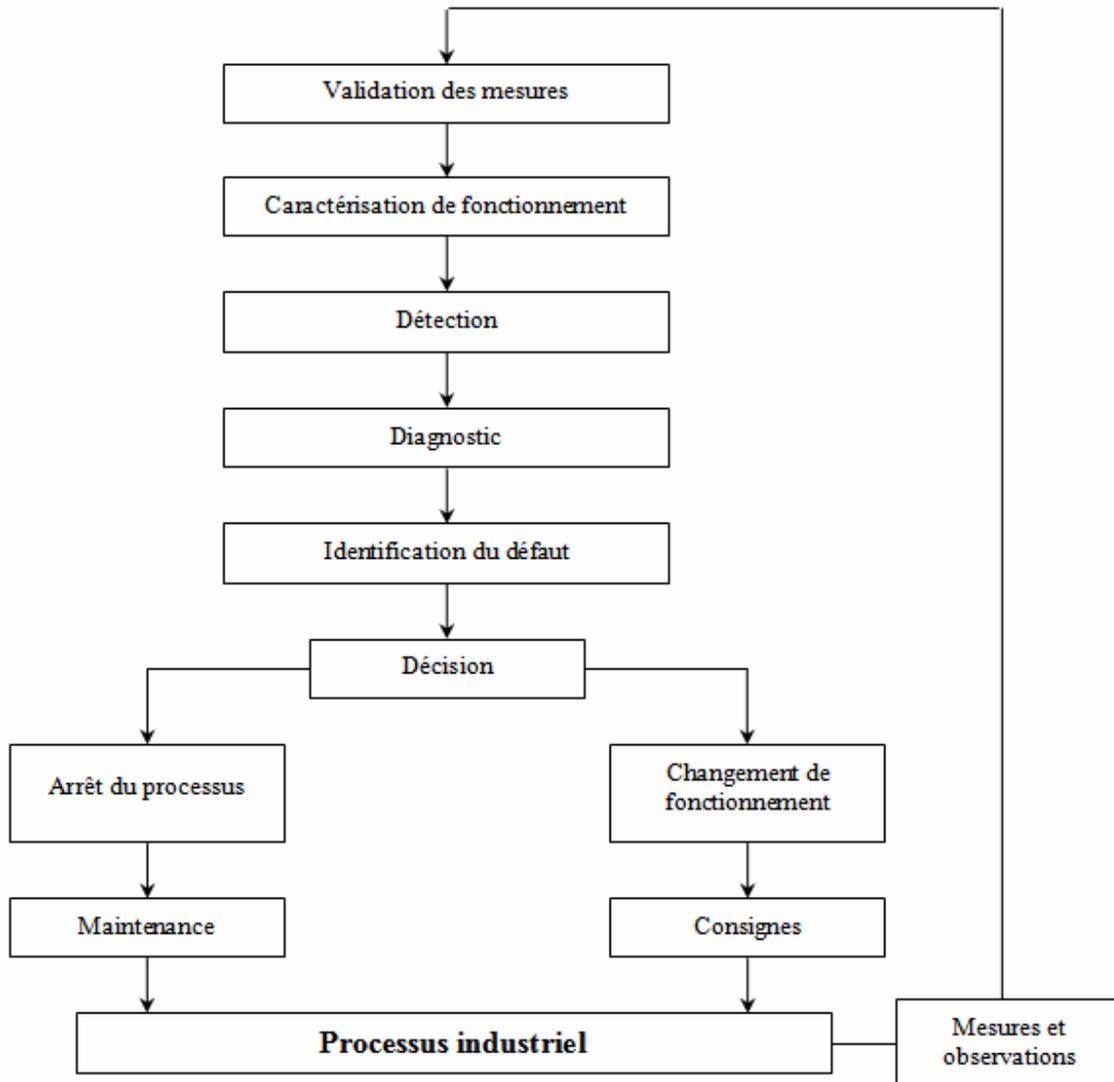


Figure I.6. Différentes phases du diagnostic industriel

I.5. Résidus

La première étape d'une approche de diagnostic fondée sur l'utilisation des modèles mathématiques consiste à générer des résidus de défauts, comme il est montré sur la Figure I.7. Ces résidus contiennent des informations sur les dysfonctionnements du processus à surveiller. Leur principe est d'observer l'écart entre les mesures réelles de systèmes et les valeurs de références données par le comportement nominal de fonctionnement de système. La génération de résidus est un problème crucial pour les systèmes de diagnostic.

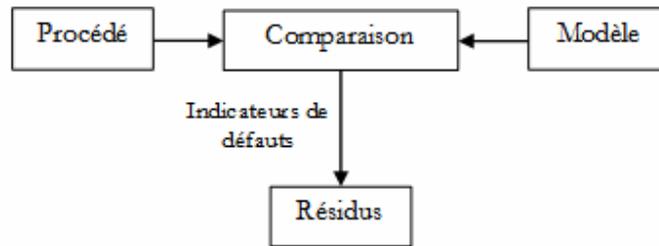


Figure I.7 : Génération de résidus

Frank et Al [58] à décomposé la structure du système de résidu en trois groupes :

1. Techniques utilisant l'espace de parité,
2. Techniques à base d'observateurs,
3. Techniques utilisant l'estimation paramétriques.

I.5.1. Approche par espace de parité

L'objectif de l'approche de génération de résidus utilisant l'espace de parité est de faire des essais et des tests sur la détermination des écart de fonctionnement entre les entrées et les sorties du processus surveillé, comme il est montré sur la Figure I.8.

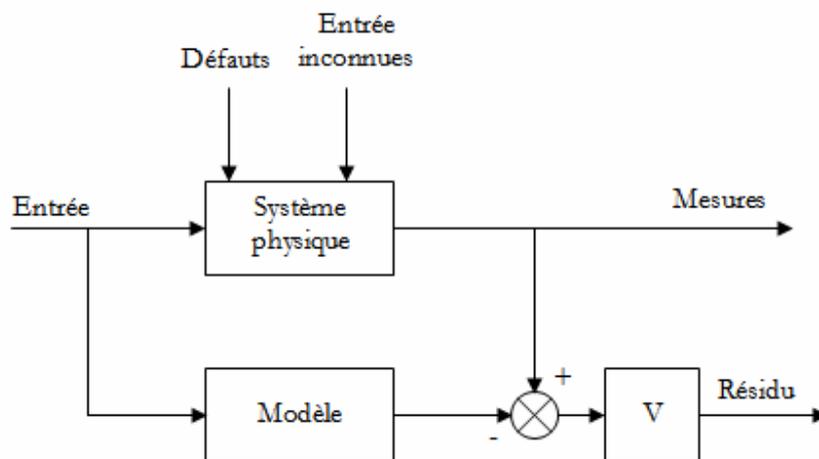


Figure I.8 : Approche de l'espace de parité dans un format entrée / sortie

I.5.1.1. Espace de parité statique

Dans la méthode d'espace de parité statique, on considère une équation de mesure à l'instant k , donnée par :

$$\begin{cases} y_k = Cx_k + \varepsilon_k + Fd_k \\ x_{(\cdot)} \in \mathfrak{R}^n, y_{(\cdot)} \in \mathfrak{R}^m, d_{(\cdot)} \in \mathfrak{R}^p, \varepsilon_{(\cdot)} \in \mathfrak{R}^n \\ C \in \mathfrak{R}^{m \times n}, F \in \mathfrak{R}^{m \times p} \end{cases} \quad (I.1)$$

Avec $y_{(\cdot)}$ est la matrice de mesure, $x_{(\cdot)}$ est la matrice des variables à mesurer, $d_{(\cdot)}$ est la matrice des défauts et $\varepsilon_{(\cdot)}$ est la matrice des bruits de mesure.

1.5.1.2. Espace de parité dynamique

Dans la méthode d'espace de parité dynamique utilise le modèle déterministe donnée par l'équation suivante :

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + F_1d(k) \\ y(k) = Cx(k) + F_2d(k) \end{cases} \quad (I.2)$$

Avec /
$$\begin{aligned} & x(\cdot) \in \mathfrak{R}^n, y(\cdot) \in \mathfrak{R}^m, u(\cdot) \in \mathfrak{R}^r, d(\cdot) \in \mathfrak{R}^p \\ & A \in \mathfrak{R}^{n \times n}, B \in \mathfrak{R}^{n \times r}, C \in \mathfrak{R}^{m \times n}, F_2 \in \mathfrak{R}^{m \times p} \end{aligned}$$

Avec $x(\cdot)$ est la matrice d'état inconnu, $u(\cdot)$ et $y(\cdot)$ les matrices des entrées et sorties de système connus.

Pour générer des équations de redondance entre les inputs et les outputs du système, il est nécessaire que l'état $x(k)$ soit écarté. Les relations de redondance qui attachent $Y_{k,k+h}$ avec $U_{k,k+h}$ sont indépendamment de $x(k)$ et qui sont déterminés en utilisant une matrice W , appelée matrice de parité, orthogonale à O_h :

$$WO_h = 0, \quad (I.3)$$

Les résidus dans ce cas sont obtenus en utilisant la matrice de parité de forme externe suivant:

$$r(k) = W(Y_{k,k+h} - T_h U_{k,k+h}) \quad (I.4)$$

Et les résidus dans ce cas de forme interne suivant:

$$r(k) = WF_h D_{k,k+h} \quad (I.5)$$

Le vecteur $r(k)$ est la matrice parité généralisé.

1.5.2. Estimation paramétriques

La méthode de génération de résidus en utilisant les techniques d'estimation paramétrique observe l'influence des défauts sur les composantes de système, comme il est montré sur la Figure I.9.

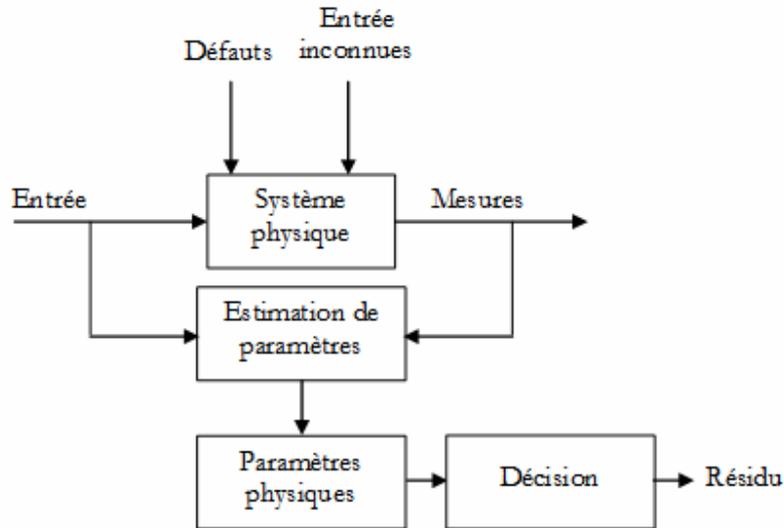


Figure I.9 : Approche d'estimation paramétrique

1.5.2.1. Minimisation de l'erreur d'équation

Le modèle du processus est écrit sous la forme :

$$y(k) = \Psi^T \theta \quad (1.6)$$

Avec θ et Ψ désignant les vecteurs de paramètres et des régresseurs :

$$\theta^T = [a_1 \dots a_n, b_1 \dots b_n], \quad \Psi^T = [y(k-1) \dots y(k-n) \quad u(k-1) \dots u(k-n)]$$

On fait appel à l'erreur d'équation $\varepsilon(\cdot)$ dans le but d'estimer les paramètres de système et on définit la fonction de transfert discrète du système par :

$$\frac{y(z)}{u(z)} = \frac{B(z)}{A(z)} = \frac{\sum_{i=1}^{n_b} b_i z^{-i}}{1 - \sum_{i=1}^{n_a} a_i z^{-i}} \quad (1.7)$$

Dans ce cas, l'erreur est donnée par :

$$e(z) = \hat{B}(z)u(z) - \hat{A}(z)y(z) \quad (1.8)$$

Avec $\hat{A}(z)$ et $\hat{B}(z)$ sont les nouvelles valeurs d'estimation.

La forme récursive de l'estimation de variable $\hat{\theta}$ basée sur l'approche MCR (moindres carrés récursifs) est donnée sous la forme suivant [96, 123] :

$$\hat{\theta}(k+1) = \hat{\theta}(k) + \gamma(k)e(k+1) \quad (I.9)$$

$$\text{Avec : } \left\{ \begin{array}{l} \gamma(k) = \frac{1}{\Psi^T(k+1)P(k)\Psi(k+1) + 1} P(k)\Psi(k+1) \\ P(k+1) = [I - \gamma(k)\Psi^T(k+1)]P(k) \\ e(k) = y(k) - \Psi^T(k)\hat{\theta}(k-1) \end{array} \right.$$

Où I est la matrice identité

1.5.2.2. Minimisation de l'erreur de sortie

Pour la modélisation de l'erreur de sortie on utilise les sorties observables sur le système pour obtenir ces erreurs de sortie comme suite :

$$e(k) = y(k) - \hat{y}(\theta, k) \quad (I.10)$$

Où :

$$\hat{y}(\theta, z) = \frac{\hat{B}(z)}{\hat{A}(z)} u(z) \quad (I.11)$$

Avec : $\hat{y}(\theta, z)$ - la sortie du modèle.

L'erreur de sortie $e(.)$ étant dans ce cas une fonction non linéaire des paramètres à estimer.

1.5.3. Approche à base d'observateurs

Beard dans [10, 99], ont été en fait les premiers à proposer l'approche appelée par certains chercheurs « par observateurs » où « en boucle fermée ». Ils ont proposé le changement de la redondance physique par des équations de détection utilisant les observateurs d'états de système. Dans cette approche, on considère le système (I.12) sans défaut :

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) \\ y(k) = Cx(k) \end{cases} \quad (I.12)$$

Avec :
 $x(.) \in \mathfrak{R}^n, y(.) \in \mathfrak{R}^m, u(.) \in \mathfrak{R}^r$
 $A \in \mathfrak{R}^{n \times n}, B \in \mathfrak{R}^{n \times r}, C \in \mathfrak{R}^{m \times n}$

Les vecteurs A , B et C étant déterminés, on peut générer un observateur afin de rétablir l'état du processus à partir des mesures $u(.)$ et $y(.)$. Cela, demande l'utilisation la forme d'observateur suivant:

$$\begin{cases} \hat{x}(k+1) = A\hat{x}(k) + Bu(k) + Ke(k) \\ e(k) = y(k) - C\hat{x}(k) \end{cases} \quad (I.13)$$

Avec $\hat{x}(.)$ est l'estimation des variables d'état de système $x(.)$, $e(.)$ est l'erreur de modélisation de la sortie de système.

La variation de l'erreur d'estimation des variables d'état de système $e_x(.)$ est obtenue par la formule suivante:

$$\begin{cases} e_x(k) = x(k) - \hat{x}(k) \\ e_x(k+1) = (A - KC)e_x(k) \end{cases} \quad (I.14)$$

Pour la détermination de la matrice K (Matrice de gain), on peut calculer la limite de l'erreur d'estimation de variables d'états vers zéro : $[\lim_{k \rightarrow \infty} e_x(k)] = 0$. Il suffit pour cela de calculer la matrice K soit choisie de manière à ce que la matrice $A - KC$ soit stable.

En présence de défauts, le modèle (I.19) est écrit sous la forme:

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + F_1d(k) \\ y(k) = Cx(k) + F_2d(k) \end{cases} \quad (I.15)$$

$x(.) \in \mathfrak{R}^n, y(.) \in \mathfrak{R}^m, u(.) \in \mathfrak{R}^r, d(.) \in \mathfrak{R}^p$
 $A \in \mathfrak{R}^{n \times n}, B \in \mathfrak{R}^{n \times r}, C \in \mathfrak{R}^{m \times n}, F_1 \in \mathfrak{R}^{n \times p}, F_2 \in \mathfrak{R}^{m \times p}$ / Où $d(.)$ est le vecteur des défauts.

L'erreur d'estimation des variables d'état et de la sortie de système sont donnée par l'équation suivante:

$$\begin{cases} e_x(k+1) = (A - KC)e_x(k) + (F_1 - KF_2)d(k) \\ e(k) = Ce_x(k) + F_2d(k) \end{cases} \quad (I.16)$$

Dans cette représentation la présence d'un défaut est conditionnée par : $F_1 - KF_2 \neq 0$ soit vérifiée.

Les différentes méthodes de génération que nous venons d'exposer génèrent des résidus classiquement répertoriés en deux groupes [70, 113], des résidus structurés [71], ou des résidus directionnels [72].

La forme générale utiliser pour la détermination des résidus est donnée par:

$$r(k) = y(k) - \hat{y}(k) \quad (I.17)$$

Dans le cas d'occurrence d'un défaut, le résidu $r(.)$ est différent de la valeur zéro et égale à zéro dans le cas de fonctionnement normale.

I.6. Différentes types de défauts

Pratiquement, un défaut est spécifié par une changement de fonctionnement normal ou à anormale d'un processus industriel. Dans la pratique industrielle il existe plusieurs types de défauts; tels que les défauts avec changement brusque de mode et les défauts à dérive lente et d'autre natures de défauts.

I.6.1. Défaut avec changement brusque de mode

Un défaut avec changement brusque de mode est donnée par son dynamique temporel, il correspond à une défaillance brusque, ce type de défaut est donnée par la formule suivante:

$$F(t - t_f) = \begin{cases} \delta & t \succ t_f \\ 0 & t \prec t_f \end{cases} \quad (I.18)$$

Avec t_f est le temps d'apparence de défaut, $(t - t_f)$ est la dynamique du défaut et δ est le seuil de détection.

I.6.2. Dérive lente de défaut

Le défaut à dérive lente a un dynamique temporel lente, ça variation temporelle est donnée par la formule suivante:

$$f(t - t_f) = \begin{cases} \delta(1 - e^{-\alpha(t-t_f)}) & t \geq t_f \\ 0 & t \prec t_f \end{cases} \quad (I.19)$$

avec α et δ des constantes.

La nature de type de défauts peuvent être groupés en défauts de type additive ou de type multiplicative, montrés sur la Figure I.10, selon leurs conséquences sur les caractéristiques du système.

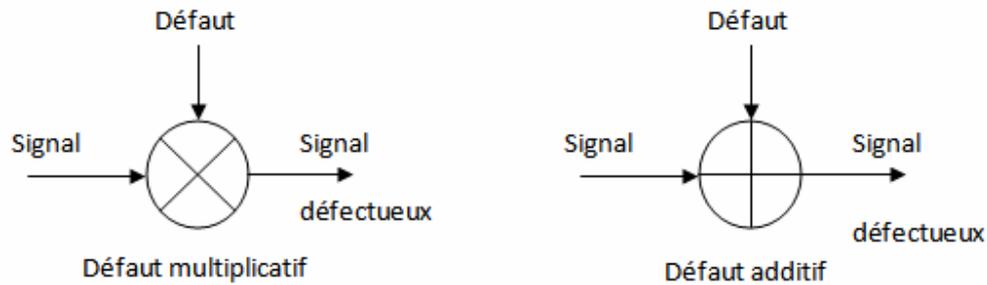


Figure I.10: Nature des défauts

I.7. Classification des méthodes de diagnostic

Les techniques de diagnostic se partagent en deux types, comme il est montré sur la Figure I.11. L'une repose sur l'utilisation des redondances d'informations pour caractériser l'état ou le mode fonctionnement de système à l'aide de connaissance fournie par le modèle mathématique, puis décider s'il est normal ou anormale (méthodes qualitatives), l'autre méthode repose sur l'extraction des informations sur le système afin d'analyser les données fournies qui permet de décider l'état du système est normale ou anormale (méthodes quantitatives).

Les méthodes de diagnostic utilisées dans les différents secteurs industriels dépendent de la constitution et la spécification de chaque processus (thermique, électrique, mécanique,..) qui permet de choisir la méthode convenable à la suite de diagnostic. Ces méthodes doivent affirmer les spécifications suivantes :

- Le diagnostic doit être facile à implémenter,
- Le nombre de capteurs nécessaire pour le diagnostic doit être minimal,
- Le diagnostic doit être prédictif,
- Le diagnostic doit être réalisable en temps réel,
- Le diagnostic doit être concevable algorithmiquement.

Donc, les approches de diagnostic en générale se divisent en trois catégories: Les approches internes, les approches externes et les approches utilisant les modes de raisonnement logique.

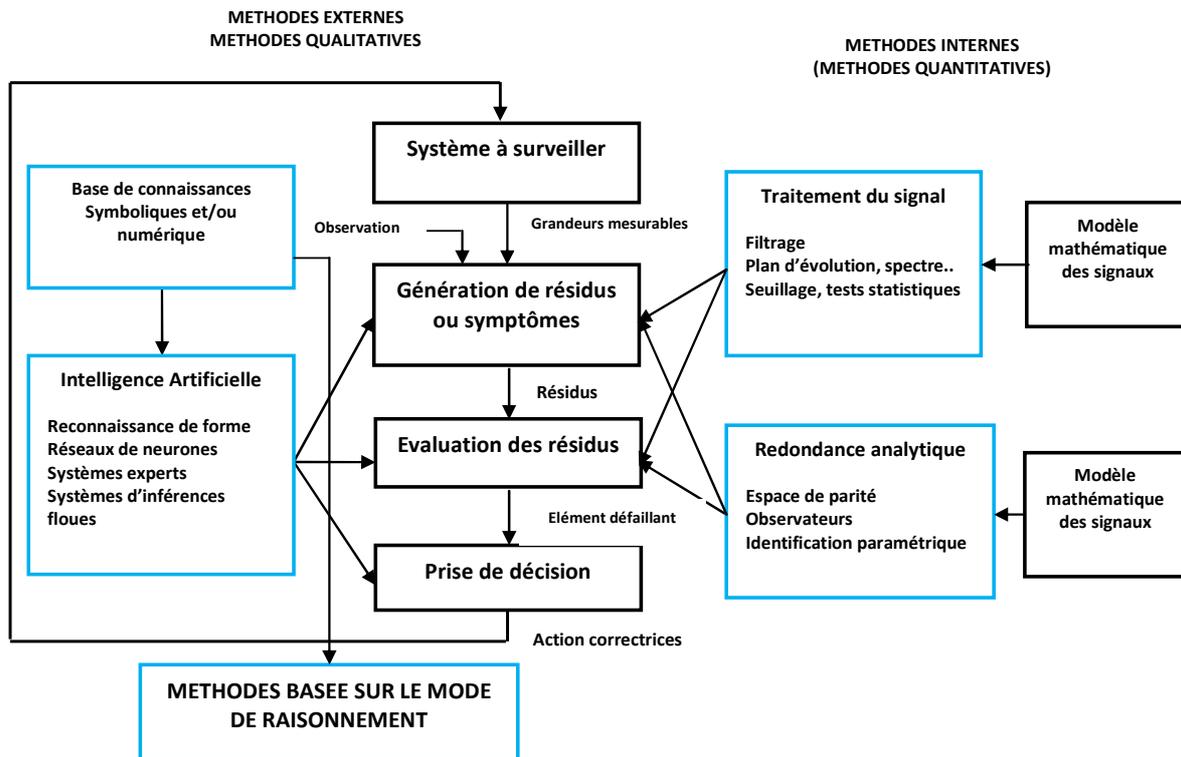


Figure I.11: Classification des méthodes de diagnostic

I.7.1. Méthodes internes de diagnostic

La méthode de diagnostic interne (boite blanche) repose sur des analyses topologiques (structurelles) ou fonctionnelles détaillées du système. Citons : Identification, estimation des paramètres, tests d'hypothèse, modélisation, reconnaissance des formes, analyse de systèmes, systèmes experts à connaissances profondes. comme il est montré sur la Figure I.12.

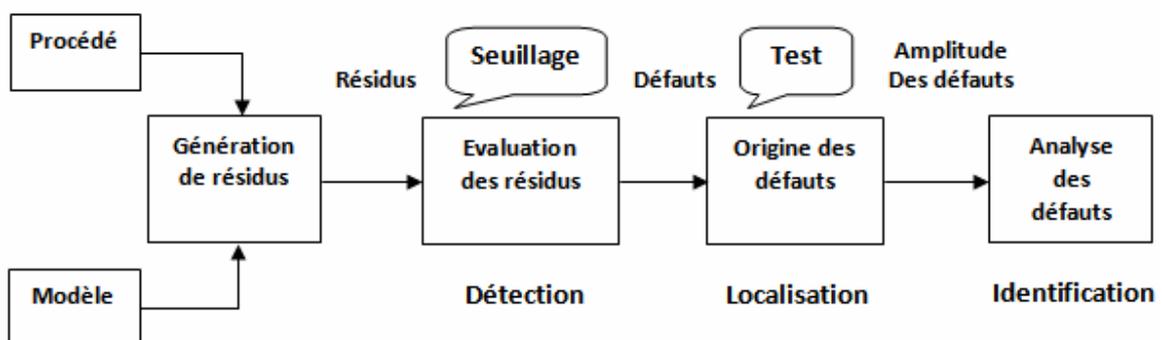


Figure I.12: Diagnostic à base de modèle

Elles présentent une meilleure voie pour établir un diagnostic car elles s'appuient sur des modèles simulant le fonctionnement des matériels. La connaissance de ces modèles qui se basent de plus en plus sur les techniques de la valeur et de l'analyse fonctionnelle permet d'utiliser des raisonnements inductifs ou déductifs pour identifier les causes de défaillance, comme il est montré sur la Figure I.13.

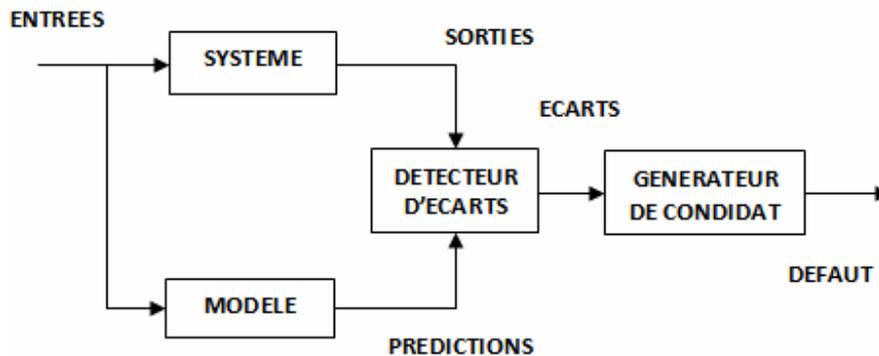


Figure I.13: Méthodes internes de diagnostic

1.7.2. Approche externes de diagnostic

Les approches externes dédiées au diagnostic sont des techniques soit à base de connaissances, soit des techniques empiriques utilisant le traitement du signal. Ces approches ne reposent pas sur la connaissance des grandeurs d'entrée/sortie du système. Citons : analyse des données, analyse statistique, reconnaissance des formes, réseaux de neurones, traitement du signal, diagnostic flou, systèmes experts à connaissances de surface.

Elles s'appliquent dans les situations où la modélisation des mécanismes reliant les causes des défaillances et des dégradations ne sont pas d'intérêt économique compte tenu des enjeux recherchés.

1.7.3. Approche utilisant le mode de raisonnement

Les approches utilisant les modes de raisonnement logique sont fondées sur la façon de raisonnement pour remonter à l'origine de la défaillance, c'est à dire par approche orientée mauvais ou bon fonctionnement. Une autre typologie vise à séparer les approches utilisables à partir d'une expérience sur les défaillances du processus industriel, des approches applicables aux nouveaux systèmes [8].

L'analyse des systèmes est un processus orienté vers l'acquisition et le traitement d'informations spécifiques au système et pertinentes vis-à-vis d'un objectif donné, ce processus aboutit à

l'obtention d'un modèle du système ; la modélisation, résultat de l'analyse fonctionnelle et /ou dysfonctionnelle [11], permet en particulier la résolution des problèmes de diagnostic des défaillances.

I.7.3.1. Approches orientées mauvais fonctionnement (MF)

Ces approches (MF) peuvent être assimilées aux techniques de diagnostic internes et externes reposant sur des analyses de mauvais fonctionnement. Un modèle retraçant le comportement du système industriel en présence de défaillance est un modèle MF. L'attachement entre les observations et un modèle dégradé de fonctionnement permet à conclure l'existence de défaut ciblé par le modèle. Une différenciation est faite entre les méthodes numériques et les méthodes symboliques. La Figure I.14 montre la procédure orientée mauvais fonctionnement.

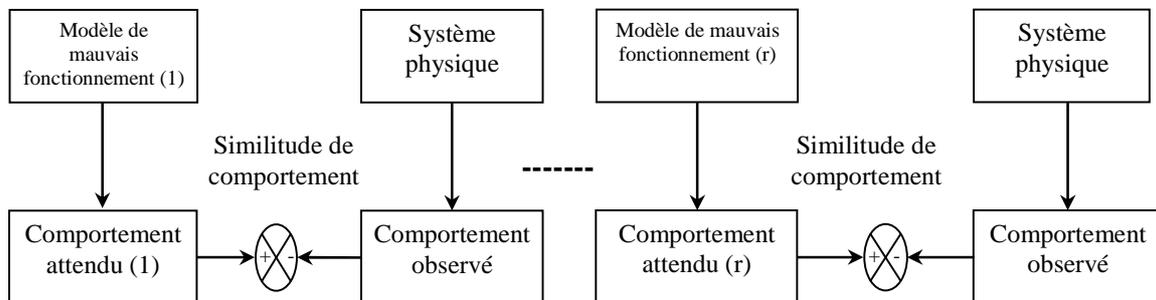


Figure I.14 : Procédure orientée mauvais fonctionnement (MF)

I.7.3.2. Approches orientées bon fonctionnement (BF)

Ces approches (BF) s'appuient sur une description profonde (un modèle de bon fonctionnement) de tout ou partie du processus à surveiller et sur une mesures de son dynamique. Dans ce type d'approche, il faut donc déduire une différence de structure à partir de la différence de comportement. La Figure I.15 montre la procédure orientée bon fonctionnement.

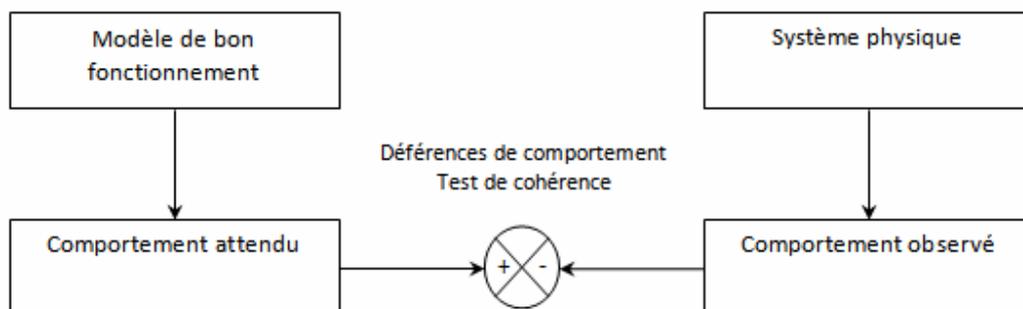


Figure I.15: Procédure orientée de bon fonctionnement (BF)

I.8. Approches de diagnostic industriel

Les techniques de diagnostic de défaillances utilisées dans les différents secteurs industriels sont très variées. Leur principe général est fondé sur l'utilisation des données réelles de système avec la détermination des modèles de références de son fonctionnement nominal ou défaillants. Cette forme, sous laquelle se présente la connaissance sur le système, conditionne les différentes méthodes utilisées pour le diagnostic [11].

I.8.1. Méthodes d'analyse fonctionnelle

L'analyse fonctionnelle permet d'établir de façon lisible et effectuée les liens fonctionnels entre les différentes composantes et éléments de système à travers la description du comportement du système sous l'angle structurel et fonctionnel. Elle constitue particulièrement un préalable de traitement de la valeur et de la disponibilité de fonctionnement en apportant les bases concrètes, logiques et exhaustives à leur mise en œuvre.

I.8.2. Méthodes d'analyse dysfonctionnelle

L'analyse dysfonctionnelle s'appuie sur une méthodologie rigoureuse et des outils puissants qui permettent la modélisation des défaillances fonctionnelles. Ainsi, les méthodes mises au point pour les études du danger et de la sûreté de fonctionnement permettent la résolution des problèmes de diagnostic de défaillances. Le principe de ces approches consiste à élaborer de manière absolue les relations entre les causes et leurs effets observables par des opérateurs ou des systèmes de traitement de l'information.

I.8.3. Méthodes déductives

Les approches déductives de diagnostic ressemblent à des techniques ascendante où l'on détermine toutes les arrangements d'évènements de base possibles qui pouvant réaliser un évènement indésirable, dans ce type on trouve l'approche des Arbres de Défaillances ou AdD. L'AdD [11], est une technique d'analyse basée sur un raisonnement déductif ayant pour objectif de représenter graphiquement au moyen d'une structure arborescente où avec des relations logiques les diverses possibilités d'évènements non souhaités.

1.8.4. Méthodes inductives

Pour les approches inductives, tels que la démarche de la méthode la plus couramment utilisée l'AMDEC. Cette méthode est une méthode traitement critique qui consiste à modéliser de façon systématique les dangers de dysfonctionnements d'un système puis d'en rechercher les origines et leurs conséquences.

Avant d'aborder l'analyse proprement dite, il est indispensable de définir le système et la phase de fonctionnement pour laquelle l'étude sera menée, et d'identifier les fonctions des éléments du système tout en fixant le seuil de décomposition. La mise en pratique de l'analyse consiste à analyser les mécanismes de défaillances et ce à travers :

- L'identification des modes de défaillance de tous les éléments du système.
- La recherche des causes possibles de défaillance, pour chaque mode de défaillance identifié.
- La recherche des effets sur le système et sur l'utilisateur, pour chaque combinaison cause-mode de défaillance.
- La recherche des détections possibles, pour chaque combinaison cause-mode de défaillance.

1.9. Redondances

1.9.1. Modélisation physique

Contrairement à la modélisation des connaissances issues de l'analyse des Systèmes, la modélisation physique des processus prend en compte les modèles représentant les phénomènes internes par la représentation du comportement dynamique de système. L'identification est fondée sur la détermination d'un modèle mathématique pour différents couples d'entrées/sorties et au sens d'un critère donné.

Les méthodes de diagnostic par modélisation physique proviennent des domaines de l'automatisation des procédés et de la simulation numérique. Elles utilisent des connaissances basées sur le comportement de fonctionnement et la profondeur du diagnostic fourni par ces méthodes dépendra du degré de finesse de la modélisation retenue.

Dans le domaine de l'automatisme, la détection des problèmes de défaillance et de pannes est connue sous le nom de détection et identification de défaillances basée sur un modèle. Toutes les méthodes de diagnostic sont structurées en deux étapes, la première génère une différence entre l'état actuel et l'état

prévu, cette différence est nommée aussi un résidu, en fonctionnement normal ce résidu est nul, tandis qu'une déviation indique l'occurrence d'un défaut. La deuxième étape est comment faire une bonne décision de diagnostic.

1.9.2. Redondance analytique

Il existe deux types de redondance dans les processus technologiques; Analytique et matériel, la redondance matérielle est basée sur la redondance d'installation des capteurs. Elle a été utilisée largement dans le domaine du contrôle des processus à hauts danger tel que les installations nucléaires et dans les aéroports et les navettes spatiales, mais son utilisation reste limitée à cause des coûts supplémentaires et l'espace additionnel nécessaire.

La redondance mathématique est basée sur un ensemble des modèles mathématiques reliant l'état du système aux variables d'entrées et de sorties. Un schéma général concernant son utilisation est montrée sur la Figure I.16. La fonction de base de la redondance analytique est de comparer le comportement actuel du système avec son modèle pour l'identification. Une différence identifiée comme résidu peut être utilisée pour la détection des défaillances. Les écarts de comportement devront être adjacents du zéro lorsqu'il n'y a pas de défaillance. La génération de tel résidu est basée sur un modèle dérivé analytiquement.

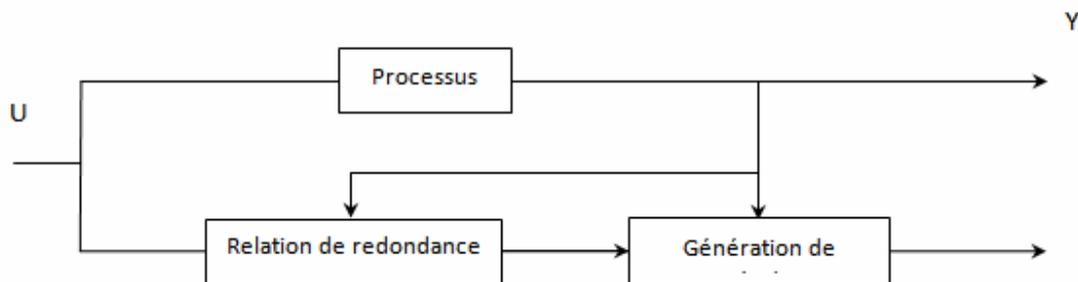


Figure I.16: Principe des méthodes basées sur la redondance analytique

Les approches basées sur la redondance mathématiques donnent des écarts de fonctionnement (résidus) qui sont insensibles aux ambiguïtés de fonctionnement et le contraire pour les défaillances. Une des techniques bien connues pour réaliser cette indépendance est la séparation des signaux de perturbations. Dans cette technique toutes les incertitudes sont analysés comme des signaux de perturbations et des filtres sont conçus pour séparer l'effet des défaillances et des perturbations pour permettre leur distinction.

I.10. Méthodes de diagnostic par analyse des signatures externes

Ces méthodes s'appliquent dans les situations où la modélisation des mécanismes reliant les causes des défaillances n'est pas techniquement possible. Elles sont basées sur le retour d'expérience. Parmi ces méthodes on trouve les réseaux de neurones et les techniques de reconnaissance des formes, la logique floue et les techniques à base de connaissances.

I.10.1. Reconnaissance des formes

Le diagnostic basé sur les système de reconnaissance des formes est une technique qui utilise les algorithmes mathématique pour faire classer des points par rapport à une classe type. Dans ce cas, la forme est définie par un ensemble de variables appelés caractères qui sont les composants de matrice de forme x ; La procédure de diagnostic basée sur les techniques de reconnaissance des formes met en œuvre quatre étapes principales qui sont résumées sur la Figure I.17.

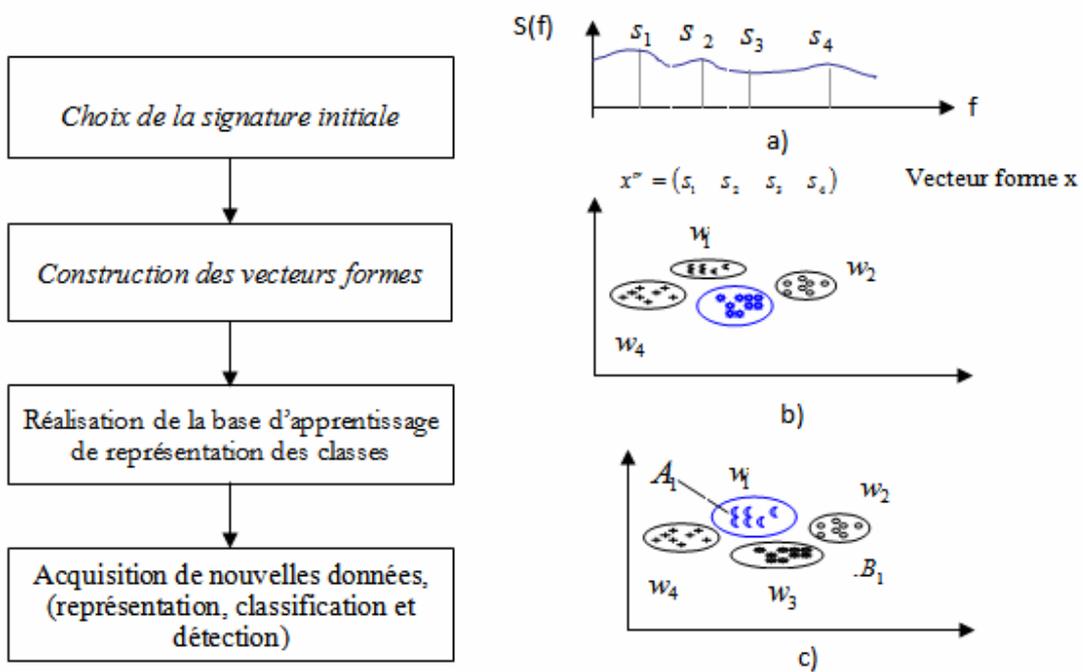


Figure I.17: Procédure de diagnostic basée sur la reconnaissance des formes

Dans ce cas, la dernière phase correspond évidemment à l'exploitation du système de diagnostic. D'autre part, après l'acquisition d'une nouvelle signature, on calcule la forme associée dans l'espace de présentation et on procède à sa classification, chose qui se réalise sans difficulté (par exemple, il faudra prendre la décision de rejeter le point B ou de le caser dans une nouvelle classe).

I.10.2. Systèmes experts de diagnostic

Un système expert est constitué de plusieurs éléments principaux, comme il est montré sur la Figure I.18, dont on peut citer [2] :

1. **Base de connaissances** : est souvent la partie stable du processus, elle est immédiatement exécutée dès l'appel du système et c'est elle qui rassemble les connaissances nécessaires à la résolution des problèmes du domaine.
2. **Base de faits** : Les faits sont les objets élémentaires de l'application ; cette base contient les informations initiales de fonctionnement de système et utilise des moteurs d'inférence pour tirer les conclusions.
3. **Moteur d'inférence** : Le mécanisme d'inférence est utilisé de façon autonome pour traiter les informations dans la base de faits avec la base de connaissances pour conclure des solutions aux problèmes traités par le système expert.

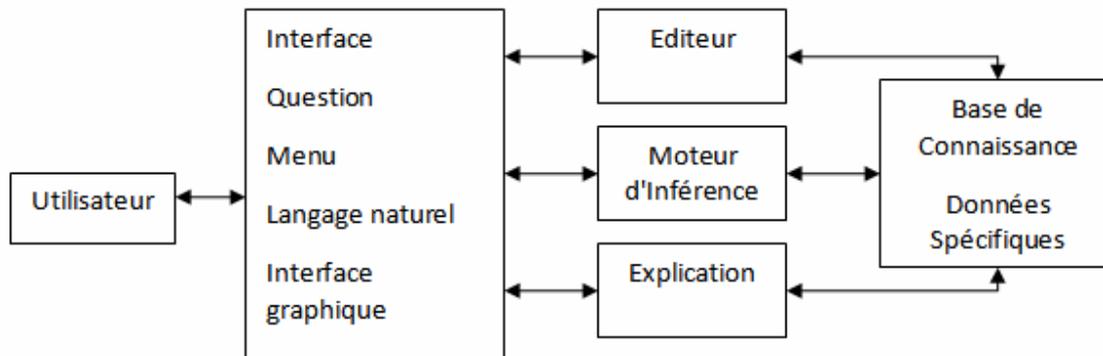


Figure I.18 : Structure d'un système expert

I.11. Diagnostic à base de la logique floue

Cette approche, contrairement à la logique du tout ou rien de G. Boole, a pour but la prise en compte de la logique de pensées humaines qui est approximative. Le concept de sous-ensemble flou a été introduit pour prendre en compte l'imprécision, la fonction d'appartenance à un ensemble flou prend des valeurs sur l'intervalle $[0,1]$ [1]. Celles-ci forment le degré d'appartenance d'un point à cet ensemble : 0 pour la non appartenance stricte et 1 pour l'appartenance stricte.

Le principe de fonctionnement du diagnostic basé sur la logique floue consiste à extraire et à calculer les signaux d'entrée, en utilisant les règles linguistiques représentées sous forme de fonctions

d'appartenance. Ces règles peuvent contenir tous les modèles possibles qui correspondent au mode de défaut considéré.

En général, la procédure de fonctionnement d'une approche floue est effectuée en 03 étapes :

1. La fuzzification,
2. L'inférence,
3. La défuzzification.

I.12. Diagnostic à base des réseaux de neurones

Un grand intérêt a été accordé à l'utilisation des réseaux de neurones pour le diagnostic de défaillances dans la littérature [2]. Ils ont été proposés pour les problèmes d'approximation de fonction et de classification. Les réseaux de neurone utilisées pour le diagnostic sont classées selon deux critères : l'architecture du réseaux (sigmoïde, radial.... etc.) et la stratégie d'apprentissage supervisé ou d'apprentissage non supervisé.

Dans le cas d'apprentissage supervisé, le réseau est configuré ce qui signifie que le problème est réduit à l'estimation des poids de connexions, comme il est montré sur la Figure I.19. Les poids sont ajustés en utilisant explicitement la différence entre les valeurs actuelles et désirées pour guider la recherche. Ce qui fait des réseaux à apprentissage supervisé un bon choix pour la classification des défaillances, car le réseau est capable d'établir des frontières de classification dans l'espace. La stratégie la plus redondante pour l'apprentissage supervisé est l'algorithme de retro propagation.

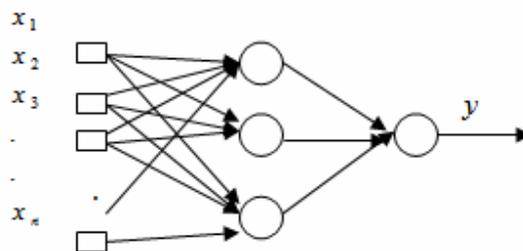


Figure I.19: Structure d'un réseau neurone feed-forward

Le réseau multicouche est le plus couramment employé pour le contrôle et la modélisation des systèmes avec une fonction sigmoïde et linéaire respectivement, dans leurs couches (internes et de sortie) est définie par l'équation suivante:

$$\begin{aligned} u_j &= f_1\left(\sum_{i=1} w_{ij}^1 x_i + b_j^1\right) \\ y_k &= f_2\left(\sum_{l=1}^N w_{lk}^2 u_l + b_k^2\right) \end{aligned} \quad (I.20)$$

Avec : f_1, f_2 sont les fonctions d'activation.

Avec l'algorithme de rétro propagation utiliser la règle d'apprentissage pour minimiser l'erreur carrée donnée par l'équation suivante

$$E_{app}(w) = \frac{1}{2} \sum_{k \in E_{app}} \sum_{j=1}^m |y_j(x_k, w) - d_{jk}|^2 \quad (I.21)$$

Avec d_k est la sortie du réseau de l'entrée x_k de $k^{ème}$ élément de l'ensemble d'apprentissage et d_{jk} est $j^{ème}$ élément de la sortie souhaité.

Donc, un réseau de neurone artificiels est composé d'automates connectés en réseau et fonctionnant en boucle combinée avec des fonctions d'activation. Les décisions sur une connaissance sont prises dans les interconnexions et en relation avec les fonctions de transition.

I.13. Conclusion

Dans ce chapitre, nous avons présenté aux manières générales quelques définitions relatives sur le diagnostic des systèmes. En effet nous avons donné un bilan détaillé sur les méthodes de diagnostics. Dans ce contexte nous avons exposé les techniques de diagnostics les plus couramment utilisées dans littératures, les approches à base de modèles et celle sans modèle. La sélection de l'un des ces approches est basée essentiellement sur la connaissances approfondie sur le système. Ainsi que l'étude et l'analyse précise sur le comportement réel du processus en présence de modèle qui permettant de suivre leur situation réel et pour corriger l'approche de diagnostic ainsi que pour diminuer le coût relatif aux pannes affectants ce système.

Dans notre présent travail, nous nous intéresserons aux techniques de diagnostic utilisant les méthodes qualitatives utilisant les réseaux de neurones artificielles pour la supervision du système étudié , et qui nécessite d'apprendre une connaissance de fonctionnement de notre système afin de faire un bilan fonctionnelle sur le système et cela pour avoir un système de diagnostic fiable et robuste à base de réseaux de neurones artificielles . Le chapitre suivant donnera plus de détail.

CHAPITRE II

APPROCHE DE RESEAUX DE NEURONES ARTIFICIELS

L'utilisation d'un modèle fiable de représentation des systèmes industriels souvent indispensable pour mener à bien des tâches de commande ou de diagnostic de ces systèmes. Pour cette raison, les approches à base de techniques d'intelligence artificielles constituent aujourd'hui un outil très puissant et de base pour l'aide à la décision, essentiellement pour réaliser des prédictions ou de représentations de système à commander, aussi que celles de modèles diagnostic, qui peut être obtenue soit à partir de données réelles de système à surveiller, soit à partir de représentations de références traitées sur des sorties de ces modèles. Nous présenterons dans cette partie de thèse le concept fondamental des techniques de réseaux de neurones artificielles dans un but de fournir des modèles fiables qui servent comme des mesures de protection et sécurité contre les phénomènes d'instabilité et cela par l'évaluation du comportement dynamique approfondi réalisés sur une turbine à gaz.

II.1. Introduction

Les neurones formels constituent aujourd'hui une approche de traitement de données bien adoptée, plusieurs développements ont été déployés pour plusieurs applications industrielles, utilisant les techniques d'intelligence artificielle pour la prise de décision dans les approches de diagnostic et de surveillances. Parmi ces techniques, les réseaux formels connus par leur capacité et rapidité de modélisation ont connu un grand succès pour résoudre des problèmes de non linéarités par apprentissage et par la flexibilité des solutions techniques souhaitées dans l'industrie. Les réseaux formels permettent de traiter de multiples manières l'information et de mieux comprendre les rythmes de fonctionnement dans plusieurs systèmes industriels.

Plusieurs travaux ont été réalisés et se sont imposés par l'intérêt soutenu des réseaux de neurones artificiels pour plusieurs investigations sur les machines tournantes, bien que d'autres nombreux travaux aient été réalisés sur d'autres applications industrielles pour l'identification et le contrôle des systèmes ou pour les sciences de traitement de l'information, pour résoudre les problèmes les plus complexes en termes de non linéarité et pour la prise de décision. Pour la mise en pratique une telle procédure de supervision, utilisant les réseaux de neurones artificiels, cette partie de thèse propose une présentation sur le concept de modélisation par les neurones formels, avec leurs méthodologies dédiées aux diagnostics basés sur les techniques de réseaux de neurones artificiels. Ceci va permettre de proposer par la suite de ce travail une stratégie de diagnostic pour la détection des dysfonctionnements affichants une turbine à gaz de type GE MS 3002, basée sur une modélisation autorégressive non linéaire dynamique avec entrée exogène externe (NARX). Enfin, nous détaillons les règles d'apprentissage qui sont adéquates à la catégorie de réseau formel appliquée par la suite à une turbine à gaz.

II.2. Réseaux de neurones artificiels

L'aide de l'utilisation des neurones formels a été développé par analogie aux neurones biologiques, montré sur la Figure II.1, où les neurones artificiels ont pour objectif de générer des raisonnements intelligents. En effet, le cerveau humain, est le meilleur modèle de l'un des équipements industriels, il est composé d'un grand nombre d'unités biologiques élémentaires à l'ordre de 10^{11} unités.

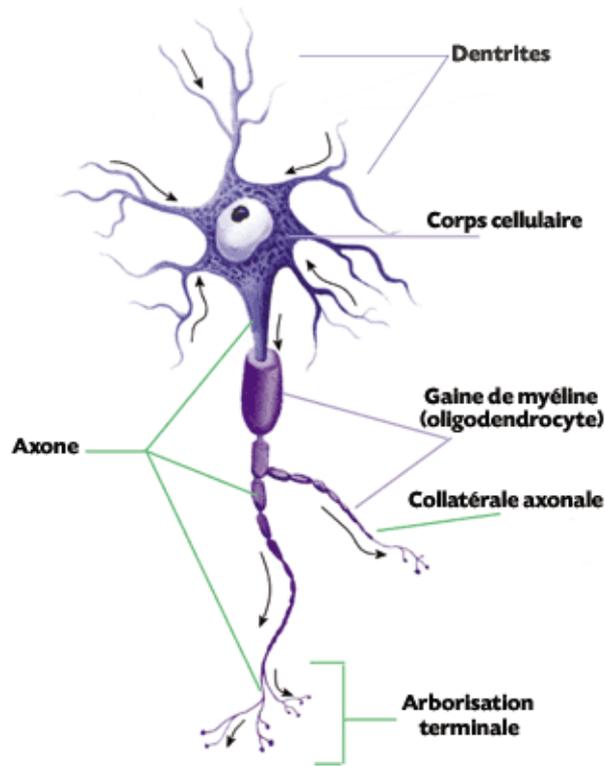


Figure II.1: Neurone biologique

La fonction d'activation d'un neurone formel est toujours comparée au seuil θ de modélisation, cette comparaison est donnée par :

$$X = \sum_{i=1}^n x_i w_i$$

$$Y = \begin{cases} +1 & \text{si } X \geq \theta \\ -1 & \text{si } X < \theta \end{cases} \quad (\text{II.1})$$

Étage	Signe	Sigmoïde	Linéaire
$Y^{\text{étage}} = \begin{cases} 1 & \text{si } X \geq \theta \\ 0 & \text{si } X < \theta \end{cases}$	$Y^{\text{signe}} = \begin{cases} +1 & \text{si } X \geq \theta \\ -1 & \text{si } X < \theta \end{cases}$	$Y^{\text{sigmoïde}} = \frac{1}{1 + e^{-\lambda*(X-\theta)}}$	$Y^{\text{linéaire}} = X - \theta$

Tableau II.1 : Fonctions d'activation comparées au seuil θ

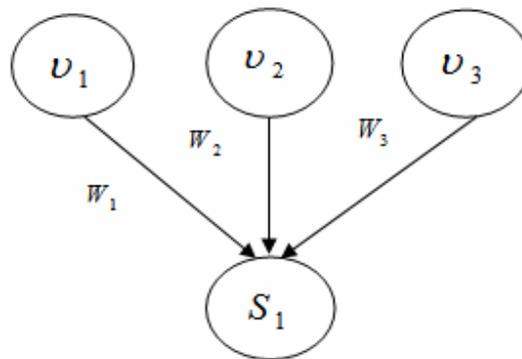
D'autre part il existe plusieurs travaux qui ont été réalisés pour plusieurs applications en engineering, où les densités d'un réseau sont traduites de manière distincte selon les catégories de neurone employé et la nature d'application.

II.3. Fonctionnement d'un neurone formel

Chaque neurone formel additionne les valeurs de ses inputs, utilisant une fonction de seuil, et renvoi les conclusions au neurone formel suivant, comme il est montré sur Figure II.2. Pour n inputs le modèle de neurone formel est écrit de la forme suivant:

$$S_i = \text{Seuil}(\sum_{i=1}^n w_i v_i) \quad (II.2)$$

Le seuil assure que les valeurs de modélisation ne dépasseront pas les limites raisonnables de modélisation, donnée généralement sur l'intervalle [0-1].



v_1, v_2, v_3 sont les entrées, w_1, w_2, w_3 sont les poids et S_1 c'est La fonction de seuil.

Figure II.2: Fonctionnement d'un neurone [15]

II.4. Model mathématique d'un neurone artificiel

Un neurone formel est une fonction algébrique non linéaire et bornée, dont la valeur dépend de paramètres appelés coefficients ou poids w , comme il est montré sur la Figure II.3. Par similitude avec le neurone biologique, la dynamique de neurone formel est modélisée par deux étapes [14] :

- Un opérateur de sommation, qui élabore le potentiel a , pour calculer le seuil d'activation θ_i ,
- Un opérateur non linéaire qui donne la limite d'activation de neurone (fonction de transfert).

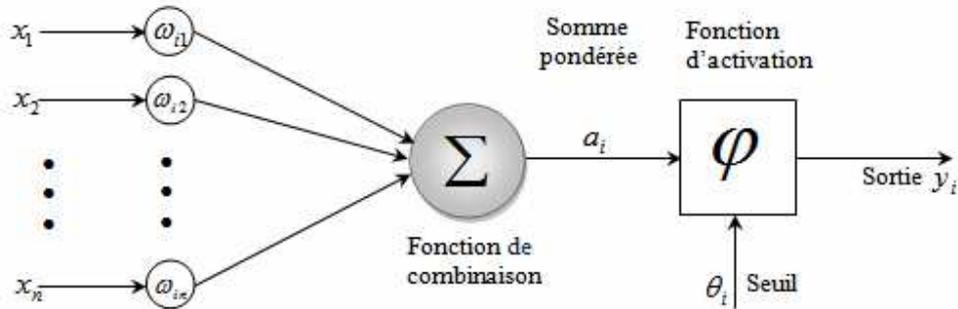


Figure II.3: Modèle non-linéaire d'un neurone formel

Dans cette Figure II.3, x_j sont les entrées du neurone i (sortie du neurone amont j), w_{ij} c'est la valeur du poids synaptique de les liaisons dirigées aux neurone i vers le neurone j . Cependant, une densité positif indique une conséquence animateur du neurone j émetteur (j) vers le neurone récepteur (i) et une densité négatif représente un effet inhibiteur. Le variable θ_i représente le seuil du neurone i qui donne la limite d'activation de neurone.

La fonction d'activation renvoie les résultats de modélisation entre la matrice des entrées et la matrice des poids synaptiques. Autrement dit, elle calcule la somme pondérée par l'équation suivante:

$$a_i = \sum_{j=1,n} w_{ij} x_j \quad (II.3)$$

A partir de résultats tirer de la somme pondérée, une fonction de seuillage φ calcule les paramètres de l'état de neurone, transmise aux neurones suivant, donnée comme suite:

$$y_i = \varphi(a_i - \theta_i) \quad (II.4)$$

Les composantes de base d'un neurone formel est, bien entendu, le neurone artificiel, comme il est présenté sur la Figure II.4. Dans le cas général un neurone formel est constitué :

- Entrées pondérées par les poids,
- Cellule de calcul l'entrée totale,
- Cellule de seuillage,
- Sortie

Chacun de ces paramètres possède une fonction ou une caractéristique bien spécifique.

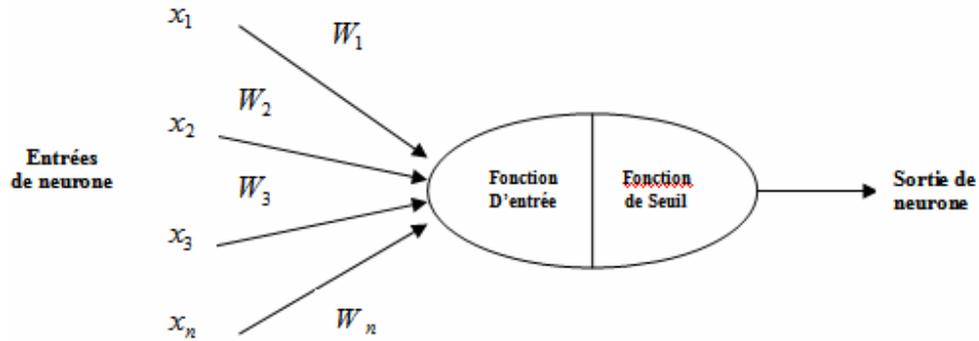


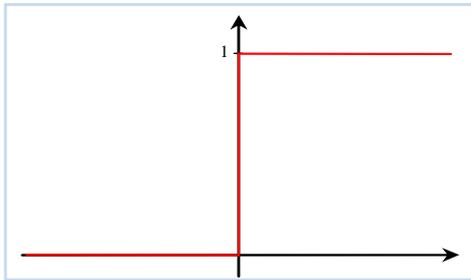
Figure II.4: Fonction caractéristique d'un réseau de neurone

L'organigramme d'application d'un neurone artificiel dans le cas simple est basé sur les quatre étapes suivantes :

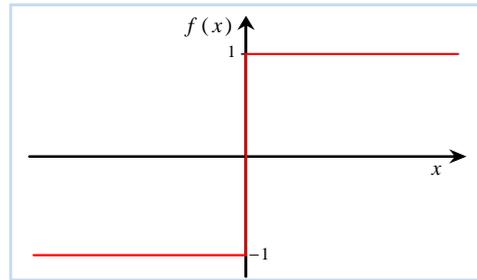
1. **Initialisation:** Cette étape permet de faire l'initialisation avec un degré.
2. **Entraînement des poids:** Cette étape permet de mettre à jour les poids du neurone artificiel.
3. **Activation:** Cette étape permet d'activer le neurone artificiel en appliquant les intrants actuels pour calculer l'extrant actuel par itération,
4. **Itération:** Cette étape permet d'augmenter les poids du neurone artificiel.

II.4.1. Activation d'un réseau de neurone artificiel

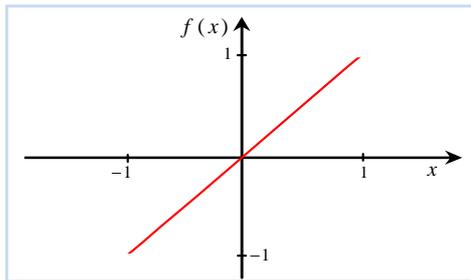
Cette étape permet d'activer le neurone artificiel en appliquant les intrants actuels pour calculer l'extrant actuel par itération, dépend du domaine d'application, comme il est montré sur la Figure II.5.



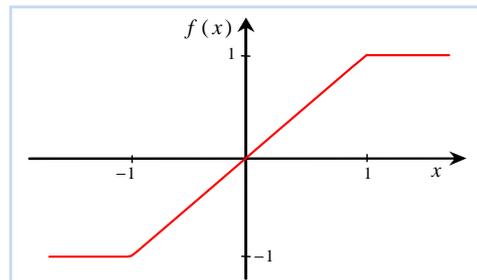
La fonction Heaviside



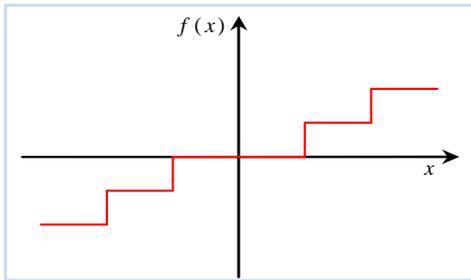
La fonction Signe



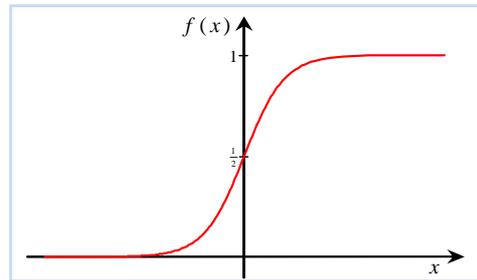
La fonction linéaire



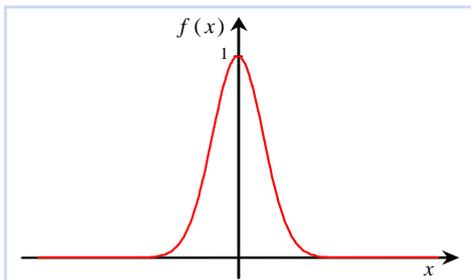
La fonction linéaire à seuil



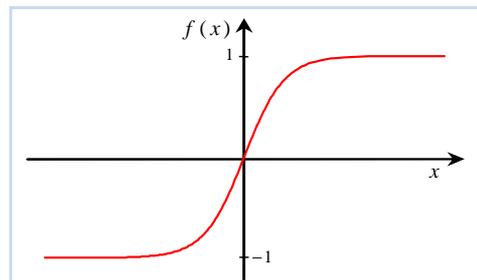
La fonction à seuils multiples



La fonction Sigmoide standard



La fonction Gaussienne



Fonction tangente hyperbolique

Figure II.5: Quelques types des fonctions d'activations

II.5. Classification et propriétés des neurones artificiels

La grande quantité de modèles connexionnistes existants, a conduit d'abord les chercheurs à les regrouper en fonction de leur utilisation. En effet, il y a plusieurs modèles de réseaux de neurones établis, selon les attributs adoptés, tels que [16]:

- Nature des cellules élémentaires que le constituent (continus binaires ou continus).
- Architecture et le nombre d'automates du réseau.
- Nature des connexions.
- Méthode d'apprentissage.
- Performances de la classification les mécanismes de mémorisation.

II.6. Architecture des réseaux de neurones

Les neurones artificiels sont classés en deux types; dynamiques (feedback) et statiques (feed forward), dans les réseaux statiques, il n'y a pas d'élément de rétroaction ou de retard, et la sortie peut être identifié directement à partir de données d'entrée via des connexions feed forward. Dans les réseaux dynamiques, la sortie dépend à la fois de l'entrée actuelle du réseau et des entrées, des sorties ou des états actuels ou antérieurs du réseau. La Figure II.6 montre la structure d'un réseau de neurones perceptron multicouche avec 03 couches et la figure II.7 montre un réseau récurrent avec deux couches.

II.6.1. Réseaux de neurones statiques

Les neurones dans les réseaux multicouches, présenté sur Figure II.6, sont regroupés en couches qui sont connectées à la direction du signal de passage (de gauche à droite). Dans ce sens, Il n'y a pas de connexions latérales dans chaque couche et pas de connexions de rétroaction ou retard dans le réseau. Cette catégorie de réseaux est connue par PMC. Il existe au moins une couche cachée dans les réseaux.

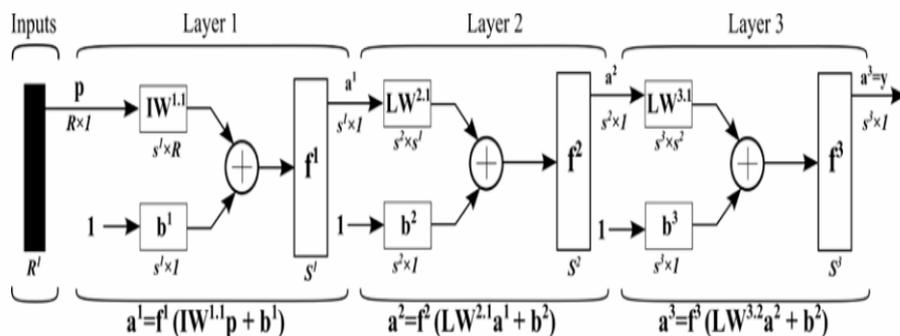


Figure II.6 : Perceptron Multicouche PMC à trois couches

II.6.1.1. Réseaux monocouche

Les réseaux sans couches cachées, sont les réseaux les plus simples, comme il est montré sur la Figure II.7. Ils sont utilisables pour des problèmes de classification et d'approximation. Leur avantage est que l'apprentissage du réseau converge vers une solution optimale. Cela est dû au fait que c'est un système linéaire. Leur inconvénient est qu'ils peuvent seulement classifier ou approximer les problèmes linéaires et ne peuvent résoudre un problème non linéaire.

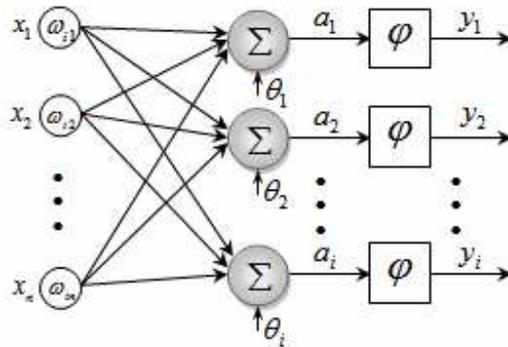


Figure II.7: Réseau de neurones monocouche

II.6.1.2. Réseaux multicouches (MLP)

Un réseau monocouche ne permettant pas de résoudre des problèmes non linéaires, les réseaux multicouches qui sont des systèmes non linéaires ont été inventés, comme il est montré sur la Figure II.8. Les réseaux de ce type possèdent trois sortes de couches [15] :

- Des couches d'entrée avec N_i unités d'entrée ;
- Des couches cachées avec N_h unités, ces couches cachées démultiplient la puissance de calcul et permettent d'aborder des problèmes plus difficiles ;
- Des couches de sortie avec N_o unités de sortie.

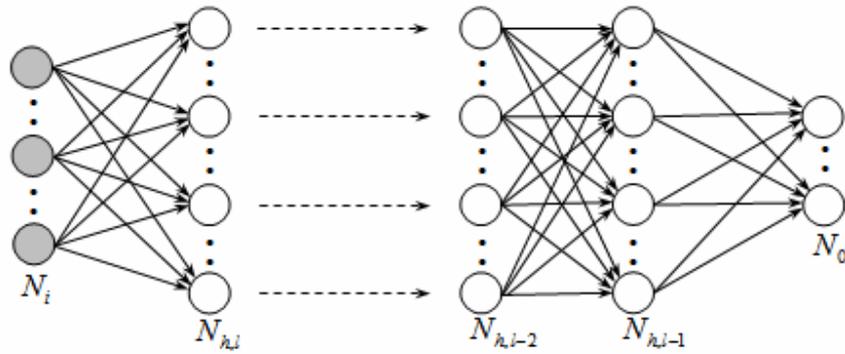


Figure II.8: Réseau de neurone multicouche

II.6.1.3. Réseaux à model radiale

Le réseau à model radiale a la même structure que le perceptron multicouches, mais la fonction d'activation est une fonction de type Gaussienne. Ce réseau, à cause de son architecture, utilise le plus souvent la règle d'apprentissage de correction d'erreur et la règle par apprentissage compétitif. Il peut avoir un apprentissage qui combine en même temps l'activation supervisé et l'activation non supervisé. Ce réseau obtient les performances comparables ou supérieures à ceux du perceptron multicouches. De plus leur apprentissage plus rapide et plus simple en font des outils de choix pour plusieurs types d'applications, dont la classification et l'approximation des fonctions, comme il est montré sur la Figure II.9. Cependant, ce réseau n'a pas si grandes recherches que le perceptron multicouches [17]. La fonction d'activation est définie comme suite:

$$y_i(x) = \exp\left(\frac{-\|x - c_i\|^2}{\sigma_i^2}\right) \quad (II.5)$$

Avec c_i est le centre de la fonction gaussienne et σ_i est le rayon de cette fonction.

Les sorties du réseau à fonction radiale sont calculées comme suite :

$$y = \sum_i^h \beta_i y_i \quad (II.6)$$

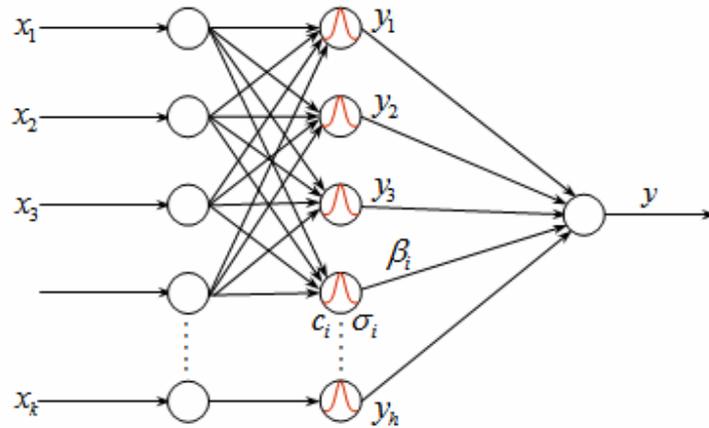


Figure II.9: Réseaux à fonction radiale (RBF)

II.6.1.4. Réseaux bouclés (dynamique)

Dans la structure des réseaux bouclés qui constituent la deuxième grande catégorie de réseaux de neurones, l'architecture la plus utilisée est donnée par la forme suivante:

$$\begin{cases} x(k+1) = \varphi[x(k), u(k)] \\ y(k) = \varphi[x(k), u(k)] \end{cases} \quad (II.7)$$

Ces réseaux sont organisés de telle sorte que chaque neurone reçoit sur ses entrées une partie ou la totalité de l'état du réseau (sortie des autres neurones) en plus des informations externes. Avec les réseaux type perceptron. Trois classes importantes de réseaux bouclés sont: les réseaux à compétition (réseaux ART et réseaux de Kohonen, « Self-organisation mapping ») et les réseaux à connexions symétriques (réseau de Hopfield) [17].

Le réseau de neurones récurrent, également appelé réseau neuronal dynamique, est un type de structure qui permet l'identification des comportements temporels d'un processus dynamique. Les sorties d'un système dynamique dépendent non seulement des entrées actuelles, mais aussi de l'historique des états et des entrées du système. Une structure de réseau de neurones actuelle est nécessaire pour modéliser ces comportements. L'un des réseaux neuronaux de rétroaction le plus couramment utilisé est le réseau autorégressif non linéaire avec des entrées exogènes (NARX). Il s'agit d'un réseau récurrent avec des connexions de retour contenant plusieurs couches du réseau. Le réseau récurrent possède de nombreuses applications. Il peut être employé pour la modélisation de systèmes complexes. En tant que prédicteur, il peut prédire la prochaine valeur de la signal d'entrée. Le modèle récurrent peut être implémenté en utilisant un perceptron multicouche pour approximer la fonction f .

Un réseau multicouche à deux couches est utilisé pour approximation. Le signal de sortie dépendant $y(t)$ est régressé sur les paramètres précédentes de la matrice de sortie et des paramètres antérieures de la matrice d'entrée indépendant. Le terme TDL est montré sur Figure II.10.

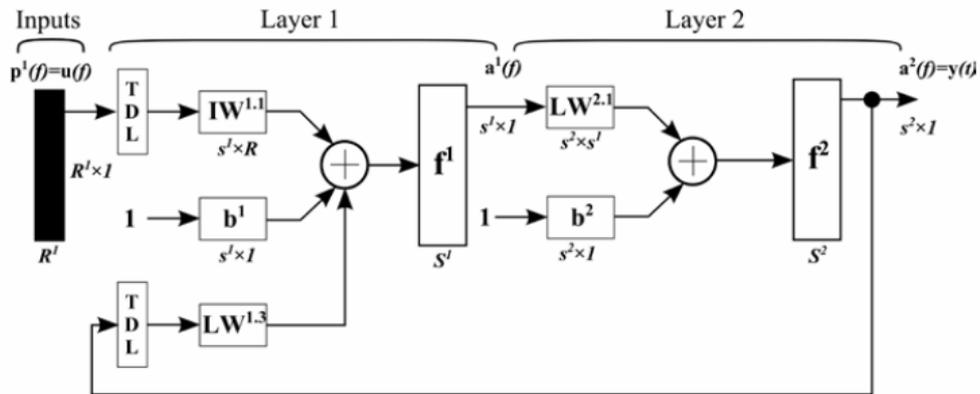


Figure II.10: Réseaux de neurone dynamique avec deux couches

II.6.1.5. Réseaux détecteurs de caractéristiques

Ces types de réseaux détecteurs de caractéristiques sont utilisés pour garantir la stabilité du modèle, car si le taux d'apprentissage tend vers zéro, mais alors le réseau perd sa plasticité. C'est pour résoudre ce problème, qu'on utilise les réseaux détecteurs de caractéristiques. Les valeurs de poids ne sont adaptées que s'il y a une approximation suffisante entre l'entrée du réseau et le modèle déjà déterminé par le réseau. En effet, il existe une résonance dans ce type de réseau. Sinon, l'entrée du système est très éloignée du prototype, on fonde alors une nouvelle classe.

II.6.1.6. Réseaux de Kohonen

Les réseaux de Kohonen (Self organisation mapping) utilisent la carte de Kohonen. Cette carte est composée de deux couches dont la première constitue les entrées de la 1^{ère} couche de réseau et la seconde est la sortie de cette couche. On peut voir la structure de cette carte sur la figure ci après. Les neurones de cette carte sont disposés en une topologie déterminée, comme il est montré sur la Figure II.11.

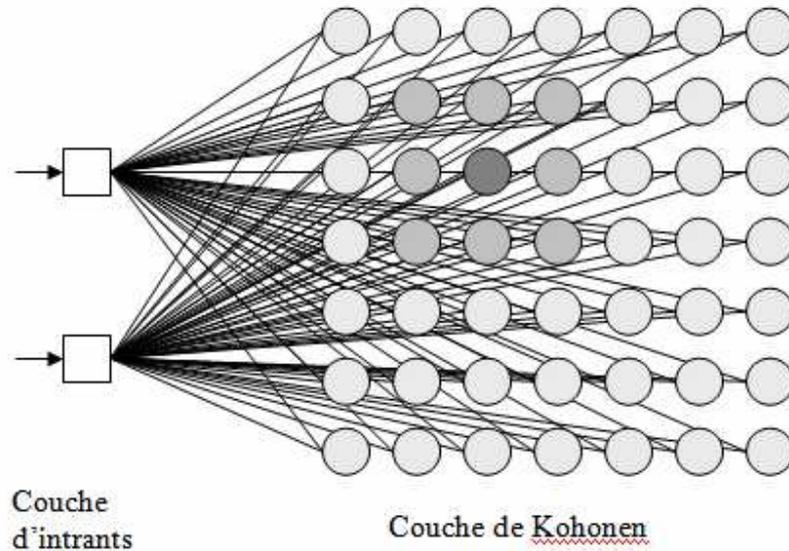


Figure II.11 : Couche de Kohonen avec deux intrants

II.6.1.7. Réseaux à connexions symétriques (réseau de Hopfield)

Dans ces réseaux il est possible de comprendre un système complexe, non pas en s'attardant sur le comportement individuel de ses composants, mais en étudiant le comportement collectif du système dans son ensemble. Comme exemple, on peut indiquer le réseau de Hopfield. Ce réseau est potentiellement utile en pratique, dès qu'il est possible de dicter par apprentissage les états stables du réseau. Dans une application, l'état d'activation initial du réseau est fixé de façon à exprimer le problème à résoudre. Le réseau évolue ensuite par une succession de propagations synchrones, jusqu'à un point fixe. Cet état stable est alors interprété comme le résultat du calcul (et donc la solution du problème). On remarque qu'en général, tous les neurones du réseau participent à la description du problème et à sa résolution. Ainsi, le réseau de Hopfield ne contient pas de neurones cachés [17].

II.7. Apprentissage des réseaux de neurones

L'apprentissage a pour but d'augmenter les performances des réseaux en se basant sur une connaissance acquise des expériences passées (prototypes). Les poids d'un RNA représentent une mémoire distribuée, cette modification affecte les poids qui relient les neurones entre eux [22].

En générale, l'apprentissage se réalise sur un intervalle longue, pendant la quelle chaque prototype d'entrée (et éventuellement de sortie désirée), est présente au réseau, plusieurs fois. L'apprentissage se fait en quatre étapes Ces étapes sont répétées jusqu'à la fin d'apprentissages:

- **Etape 1** : Initialisation des poids du réseau à des petites valeurs aléatoires.
- **Etape 2** : Présentation du prototype d'entrée au RNA. Des valeurs de sortie correspondants sont ensuite calculées après propagation d'activation.
- **Etape 3** : Calcul de l'erreur : ce terme s'emploi plus volontiers pour un apprentissage supervisé ou l'erreur tient compte de la différence entre l'activation des neurones de sortie et de la sortie désiré (lié au prototype d'entrée).
- **Etape 4** : Calcul du vecteur de correction : à partir des valeurs d'erreurs, on détermine alors la correction à apporter aux poids des connexions et aux seuils des neurones.

En pratique l'apprentissage connexionniste n'est pas une technique suffisamment bien maîtrisée, pour pouvoir se dispenser de l'intervention humaine. Les règles d'apprentissage sont souvent coûteuses en temps de calcul, un utilisateur expérimenté est souvent nécessaire pour ajuster les divers paramètres de l'apprentissage au cours de l'entraînement. Une deuxième solution et qui est en général employée, est d'effectuer un apprentissage à part sur un échantillon de prototypes présélectionnés dite base d'apprentissage.

On peut considérer les neurones formels comme des boites noire contenant l'information qu'elle doit apprendre et mémoriser. Mais au démarrage lorsqu'on choisit notre réseau, la boite noire est vide et ne contient aucune information, ni aucune connaissance sur son sujet, c'est pourquoi un apprentissage est nécessaire.

L'apprentissage d'un neurone formel consiste à adapter ses différents paramètres (poids) d'après un algorithme itératif d'ajustement ou d'adaptation lui permettant de prendre en considération toutes les données (exemples) qui lui sont fournies à son entrée et ainsi ajuster ses paramètres pour trouver le juste milieu admettant n'importe quel exemple ou donnée apparaissant à son entrée provenant de son environnement [13, 22]. Les algorithmes d'apprentissages donnent des meilleurs résultats lorsqu'on leur fournit des exemples multiples et variés ; ainsi le réseau peut assimiler toutes les connaissances. Il existe différentes règles d'apprentissage parmi lesquelles on peut distinguer [13]: Règle de Widrow-Hoff, Règle de Hebb, Règle de rétro propagation et autres règles.

En effet, les approches d'apprentissage se partagent principalement en trois catégories [45, 49]:

1. Apprentissage supervisé ;
2. Apprentissage non supervisé ;
3. Apprentissage par renforcement ou semi – supervisé.

II.7.1. Apprentissage supervisé

L'apprentissage supervisé ou l'apprentissage associatif, comme il est montré sur la Figure II.12, le réseau adaptatif w compare les sorties y en utilisant une fonction d'activation $f(d, y)$ des entrées u . Les différentes réponses sont connues à priori. On dispose d'une base d'apprentissage qui contient un ensemble d'observation sous forme des couples entrées/sorties associées, les poids sont modifiés en fonction des sorties désirées [17].

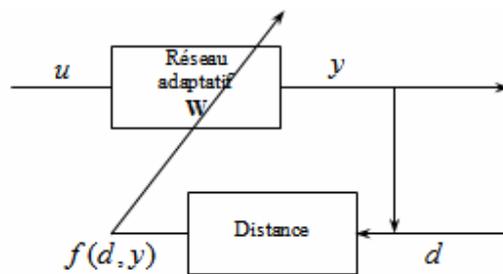


Figure II.12: Apprentissage supervisé

II.7.2. Apprentissage auto organisation

L'apprentissage auto organisation, comme il est montré sur la Figure II.13, est basé sur la détermination des probabilités possible d'élaboration de modèle adéquate pour le système à modélisé [17]. L'apprentissage auto organisation utilise les entrées de système seulement, sans le comportement de référence [18].

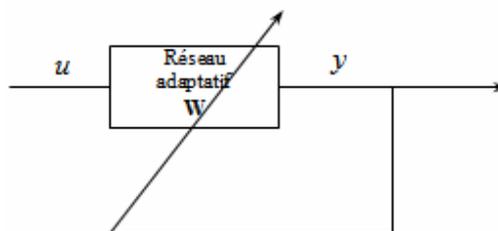


Figure II.13: Apprentissage auto organisation

Cet apprentissage se fait sur la base d'informations locales existant aux niveaux des neurones. Il découvre les propriétés collectives qui existe entre les données et sur lesquelles le réseau s'organise.

II.7.3. Apprentissage par renforcement (semi – supervisé)

Ce type d'apprentissage est moins classique que les deux derniers (ils sont les principaux). Il a d'une part en commun avec l'apprentissage supervisé la présence d'un critère qui juge l'évolution de l'apprentissage et d'autre part il ne nécessite que des entrées sans définir les sorties désirées. Comme dans l'activation non supervisé, le réseau ajuste les poids synaptiques suivant un critère de performance. Celui ci renforce les poids du réseau si le critère y est favorable et les punit dans le cas contraire [19].

II.7.4. Règles d'apprentissage

Les deux types ont pour but d'ajuster les densités de connexions entre les différents neurones, en s'accordant par certaines règles. Nous citons ci après les règles les plus répandues [2].

II.7.4.1. Règle de Hebb

Vue dans le livre « Organisation of Behavior » (1949) [Hebb, 1949]. Cette règle est inspirée de la biologie. Le principe est de renforcer les connexions entre deux neurones lorsque ceux-ci sont actifs simultanément. Elle peut être classée comme apprentissage non supervisé, ou supervisé car on sait calculer directement les poids correspondant à l'apprentissage d'un certains nombres d'exemples [2, 14].

C'est une règle non supervisé. Elle s'applique aux connexions de deux neurones et se base sur leurs potentiels. Hebb annonça en 1949 la première règle d'apprentissage : "Quand une cellule A excité par son axone une cellule B et que de manière répétée et persistante, elle participe à la genèse d'une impulsion dans B, un processus de croissance ou un changement métabolique à lieu dans l'une ou dans les deux cellules de telle sorte que l'efficacité de A à déclencher une impulsion dans B est parmi les autre cellules qui ont cet effet accrue" [2]. Ce qui signifie, si deux neurones sont actifs en même temps la synapse se renforce, sinon elle s'affaiblit.

La modification de poids dépend de la coactivation des neurones pré synaptique et post synaptique, ainsi que la montre le tableau (Tableau.I.1). A_i et A_j sont respectivement les valeurs d'activation des neurones i et j .

A_i	A_j	ΔW_{ij}
0	0	-
0	1	0
1	0	0
1	1	+

ΔW_{ij} Correspond à la modification de poids réalisée

Tableau II.2 : Règle de Hebb

Dans le cas des neurones formels, cette règle peut être modélisée par l'équation (II.8) suivante :

$$W_{ij}(t + \delta t) = W_{ij}(t) + \mu \delta W_{ij}(t) \quad (II.8)$$

Avec $\mu \delta W_{ij}(t) = \mu A_i A_j$ est la coactivité des deux neurones, $W_{ij}(t + \delta t)$ est le nouveau poids, $W_{ij}(t)$ est l'ancien poids et μ est le facteur d'apprentissage.

II.7.4.2. Règle de Delta (Windrow -Hoff)

En 1960 Widrow et Hoff ont proposé une règle d'apprentissage consistant à minimiser une fonction d'erreur quadratique. Cette erreur peut être calculée en fonction des réponses désirées et des réponses obtenus par le réseau pour chaque exemple d'entrainements. Au départ on choisit les poids W_{ij} aléatoirement, ensuite on les modifie jusqu'à ce que le réseau soit capable de calculer la sortie désirée correspondante à l'entrée donnée. Le mécanisme utilisé est la suivant : on fournit au réseau un ensemble d'exemples, ou chaque prototype est constitué d'un vecteur d'entrée et d'un vecteur de sortie désirée. Le réseau calcule pour chaque vecteur d'entrée un vecteur de sortie, en suite, il le compare au vecteur de sortie désirée. Si l'erreur résultante est inférieure à un seuil déjà fixé, l'apprentissage s'arrête. Sinon cette erreur sert à modifier les poids. La modification des poids se fait par la formule suivante.

$$W_{ij} = \eta (T_j - O_j) X_i = \eta \delta_j X_i \quad (II.9)$$

Avec $\eta \delta_j X$ est le taux d'apprentissage, T_j est le vecteur de sortie désirée, O_j est le vecteur de sortie calculée par les réseaux, X_i est le vecteur d'entrée, et $\Delta_j = T_j - O_j$ est le terme d'erreur.

L'objectif de l'apprentissage est de modifier les valeurs des poids du réseau de façon à minimiser cette erreur et à effectuer une descente du gradient.

L'algorithme de descente de gradient consiste à changer chaque poids w_{ij} d'une quantité Δw_{ij} proportionnelle au gradient de l'erreur [14], donnée par :

$$\Delta w_{ij} = \eta \frac{\partial E}{\partial w_{ij}} = \eta \sum_i (d_i - y_i) x_i \quad (\text{II.10})$$

II.7.4.3. Règle d'apprentissage compétitive

Elle qui ne concerne qu'un seul neurone. On regroupe les données en catégorie. Les neurones similaires vont donc être rangés dans une même classe en se basant sur des corrélations des données et seront représentés par un seul neurone. L'architecture d'un tel réseau possède une couche d'entrée et une couche de compétition. Une forme est présentée à l'entrée du réseau et est projetée sur chacun des neurones de la couche compétitive. Le neurone gagnant est celui qui possède un vecteur de poids le plus proche de la forme présentée à l'entrée. Chaque neurone de sortie est connecté aux neurones de la couche d'entrée et aux autres cellules de sortie (c'est une connexion inhibitrice) ou à elle-même (c'est une connexion excitatrice). La sortie dépend alors de la compétition entre les connexions inhibitrices et excitatrices [17].

$$\Delta w_{ij} = \begin{cases} \eta(x_j - w_{ij}) & \text{Si le neurone } i \text{ est le vainqueur} \\ 0 & \end{cases} \quad (\text{II.11})$$

II.7.4.4. Règle de correction d'erreurs

Cette règle s'inscrit généralement dans le paradigme d'apprentissage supervisé, c'est-à-dire dans le cas où l'on fournit au réseau une entrée et la sortie correspondante. Si on considère y comme étant la sortie calculée par le réseau et d la sortie désirée, le principe de cette règle est d'utiliser l'erreur $(d - y)$, afin de modifier les connexions et de diminuer ainsi l'erreur globale du système, le réseau va donc s'adapter jusqu'à ce que y soit égal à d .

Notez que l'apprentissage n'intervient seulement que lorsqu'une erreur est faite, dans le cas contraire, les poids demeurent inchangés. Cette règle est donc une forme modifiée de la règle d'apprentissage de Hebb.

II.7.4.5. Règle de rétro-propagation

On appelle généralisation la capacité d'un RNA de réagir correctement face à des données qui n'étaient pas présentées dans la base d'apprentissage. Les performances en généralisation d'un réseau sont les plus significatives d'un apprentissage réussi.

La règle inventée par Rumelhart, Hinton et Williams en 1986 est utilisée pour ajuster les poids de la couche d'entrée à la couche cachée. Cette règle peut aussi être considérée comme une généralisation de la règle delta pour des fonctions d'activation non linéaire et pour des réseaux multicouches. Les poids dans le réseau de neurones sont au préalable initialisés avec des valeurs aléatoires. On considère ensuite un ensemble de données qui vont servir à l'apprentissage. Chaque échantillon possède ses valeurs cibles qui sont celles que le réseau de neurones doit à terme prédire lorsqu'on lui présente le même échantillon [4].

Le développement d'algorithmes d'apprentissage supervisé pour les réseaux multicouches se heurte au problème de calcul des erreurs de sortie pour les neurones cachés. En effet, les neurones cachés n'ont pas un rôle prédéfini, c'est l'apprentissage qui les utilise à sa convenance pour former des représentations internes, à cause de l'absence d'une règle d'apprentissage convenable, les perceptrons étaient limitées à une seule couche pendant plusieurs années, mais ce type de perceptrons ne peut résoudre que les problèmes dont les données sont linéairement séparables. Les limitations du perceptron ont été levées par la découverte de l'algorithme de rétro-propagation qui a permis de résoudre le problème de calcul des erreurs associées aux neurones cachés.

La règle de rétro-propagation inventée par Rumelhart, Hinton et Williams en 1986. Elle s'utilise pour ajuster les poids de la couche d'entrée à la couche cachée. Cette règle peut aussi être considérée comme une généralisation de la règle delta pour des fonctions d'activation non linéaire et pour des réseaux multicouches. Les poids dans le réseau de neurones sont au préalable initialisés avec des valeurs aléatoires. On considère ensuite un ensemble de données qui vont servir à l'apprentissage. Chaque échantillon possède ses valeurs cibles qui sont celles que le réseau de neurones doit à terme prédire lorsqu'on lui présente le même échantillon [17].

L'algorithme de la rétro-propagation s'applique en deux étapes. La première est le forward propagation, durant laquelle l'excitation X_p est appliquée à la couche d'entrée et se propage, en avant, dans le réseau pour calculer la sortie O_p , et l'erreur $(d_p - O_p)$ par rapport la sortie désirée d_p . Durant la deuxième phase - backward propagation - cette erreur se propage en arrière pour calculer l'erreur pour chaque neurone, et effectuer des changements appropriés des poids du réseau [18, 20].

II.7.5. Algorithme de la rétro-propagation du gradient (RPG)

Les limitations des modèles neuronaux des années 60 comme le perceptron [6], ont conduit les chercheurs à abandonner. Cette ligne de méthodes d'apprentissage dans les années 80, grâce aux

travaux de Kohonen et de Hopfield, cette voie a été remise au goût du jour et a suscité un intérêt croissant de la part de nombreux chercheurs issus de différentes disciplines [2].

C'est ainsi qu'en 1985, la rétro-propagation du gradient (RPG) apparaît comme alternative aux anciens modèles. C'est un algorithme d'apprentissage adapté aux réseaux de neurones multicouches (aussi appelé Perceptron multicouche). Dès cette découverte, nous la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau en décomposant cette fonction en une suite d'étapes linéairement séparables.

De nos jours, les réseaux multicouches à rétro-propagation du gradient reste le modèle le plus étudié et le plus productif au niveau des applications. La rétro-propagation est l'algorithme le plus utilisé parmi les plusieurs techniques de modification des poids. Elle repose sur la méthode du décente de gradient. Il s'agit de calculer l'erreur E en fonction des couples, entrée-sortie choisies pour l'apprentissage ensuite minimiser cette erreur par la descente du gradient [25]. Après initialisation des poids, l'algorithme sera décrit par deux phases :

- le passage de l'activation de l'entrée vers la sortie du réseau et c'est la phase avant " feed- ward ".
- l'adaptation de l'algorithme de rétro-propagation afin de diminuer l'erreur entre la sortie obtenue et la réponse désirée. C'est la phase arrière " feed- back ".

Phase avant

1. Appliquer la matrice d'entrée et la matrice de réponse désirée,
2. Calculer les entrées des couches internes, utilisant la formule suivante:

$$Net_{pi}^h = \sum_{i=1}^n W_{ij}^h X_j^p + \theta_j^h \tag{II.12}$$

3. Calculer les sorties des couches internes sous la forme de :

$$I_j^p = F(Net_{pi}^h) \tag{II.13}$$

4. Calculer les entrées des neurones des sorties par :

$$Net_{pk}^o = \sum_{j=1}^n W_{ij}^o X_j^p + \theta_j^h \tag{II.14}$$

5. Calculer les sorties du réseau par :

$$I_k^p = F(Net_{pk}^o) \tag{II.15}$$

Phase arrière

6. Calculer le terme d'erreur pour la couche de sortie :

$$\delta_k^p = (T_k^p - O_k^k)F'(Net_{pk}^o) \quad (II.16)$$

7. Modifier les poids de la couche de sortie :

$$W_{kj}^o(t+1) = W_{kj}^o(t)\eta\delta_{pk}^o I_j^p \quad (II.17)$$

8. Calculer le terme d'erreur des couches internes (cachées) :

$$\delta_{pi}^h = F'(Net_{pi}^h)\sum \delta_{pk}^o W_{ki}^o \quad (II.18)$$

9. Modifier les poids des couches internes (cachées) :

$$W_{ij}^h(t+1) = W_{ij}^h(t)\eta\delta_{pi}^h X_j^p \quad (II.19)$$

où η est le pas d'apprentissage

10. Refaire pour chaque vecteur d'entraînement.

11. Calculer l'erreur E , par l'équation suivante:

$$E = \frac{1}{2} \sum_K (T_k^p - O_k^p)^2 \quad (II.20)$$

12. Tant que l'erreur E n'a pas atteint le seuil fixé. Refaire les étapes de 1 à 10.

13. Fin de l'algorithme de la rétro-propagation

Notons que l'indice du couple W_{ij} est le densité de connexion entre le neurone j et le neurone i , Net_{pi}^h est l'entrée du neurone j , p est la couche cachée, Net_{pk}^o est l'entrée globale le du $K^{ème}$ neurone, O_j^h sont les poids fictifs du neurone j pour l'exemple p .

La couche cachée et F est la densité d'activation de la forme sigmoïde, elle est écrite sous les équations suivantes:

$$F(Net) = \frac{1}{1 + e^{-\sum W_{ij} + \theta_i}} \quad (II.21)$$

$$F'(Net_{pi}^h) = \frac{df(Net_{pi}^h)}{d(Net_{pi}^h)}$$

On peut opérer avec cette méthode de deux manières différentes : data adaptive learning, ou block adaptive learning.

II.7.5.1. Apprentissage par rétro-propagation

La phase de développement d'un réseau à rétro-propagation du gradient se fait par un algorithme à apprentissage supervisé. Cet algorithme vise à faire des regroupements entre les matrices de donnée d'entrée et les matrices donnée de sortie souhaités [2].

En fait, l'idée de base de cet algorithme est que l'on veut minimiser le critère d'erreur quadratique en fonctionne des poids de connexions de réseau.

$$E = \frac{1}{2} \sum_{i=1}^m (y_d - y_i)^2 \quad (II.22)$$

Donc, l'erreur définie par les écarts entre les outputs désirés et les outputs obtenus doit être minimisée par rapport aux poids de connexions.

Les réseaux de neurones multicouches à rétro propagation du gradient, par leurs capacités remarquables d'apprentissage et de reconnaissance des formes constituent de manière incontestable l'outil privilégié du diagnostic industriel à base de signatures externes. C'est la raison pour laquelle, il est important de modifier les conditions initiales du réseau (poids des connexions nombre des cellules et des couches) pour vérifier la robustesse des résultats, pour la résolution de problèmes de classification avec rejet technique indispensable en cas d'évolution lent des signatures de réseaux de neurones.

Les réseaux de neurones sont bien adaptés à la résolution des problèmes de diagnostic, utilisant la classification automatique des signaux et des formes. Dans ce contexte on distingue plusieurs applications des réseaux de neurones pour le diagnostic des défaillances et en particulier, pour le diagnostic des pannes des machines industrielles.

II.8. Conclusion

Dans ce chapitre nous avons exposé, les notions fondamentales relatives aux réseaux de neurones, et de confirmer qu'un réseau de neurones n'est rien d'autre qu'un approximateur de modèle basé sur l'interconnexion de plusieurs entités élémentaires appelées neurones. Cette étude des modèles des réseaux de neurones, nous a permis de dégager les principales caractéristiques qui les différencient des techniques classiques utilisées dans la résolution des problèmes posés dans plusieurs domaines industriels. Et par le choix de la meilleure structure du réseau dépend de plusieurs paramètres mise en jeu selon l'application. Par ailleurs, le modèle multicouche est le plus utilisé parmi les différents modèles des réseaux neuronaux, car il permet d'approximer n'importe quelle fonction de transfert donnée, après un choix approprié de ses paramètres.

Les réseaux de neurones multicouches à rétro propagation du gradient, par leurs capacités remarquables d'apprentissage et de reconnaissance des formes constituent de manière incontestable l'outil privilégié du diagnostic industriel à base de signatures externes. Cela est l'objectif de travail dans cette thèse, où nous allons utiliser des réseaux de neurones multicouches pour simuler le comportement dynamique du rotor d'une turbine à gaz, tournant à haute vitesse, destinée à conduire un compresseur centrifuge utilisé dans le transport de gaz naturel. Une chose qui sera détaillée dans les parties suivantes de ce travail.

CHAPITRE III

DETECTION DES VIBRATIONS DES TURBINES A GAZ

La maîtrise des vibrations des machines tournantes reste toujours un déficit industriel pour les entreprises possédants ce type de machines. Dans le cas des turbines à gaz, la déformation dynamique non maîtrisée d'une structure des boucliers et les ailettes d'une turbine peut entraîner un vieillissement prématuré des composants, ou encore des nuisances sonores et vibratoires inacceptables. L'objectif de ce chapitre est la modélisation de ce phénomène en utilisant les techniques de réseaux de neurones artificiels. Notre travail est orienté dans ce sens pour illustrer et montrer comment dans une politique de maintenance, les vibrations sont mesurées, traitées, surveillées et servent pour un diagnostic pour pouvoir apprécier l'état mécanique de la turbine à gaz examinée.

III.1. Introduction

Tous les équipements tournants en exploitation produisent des vibrations, dans ce type de machines. En effet, certaines conditions de marche entraînent des anomalies dans le fonctionnement de la turbine, où l'apparition de forte vibration provoque des endommagements dans les organes de la turbine. L'objectif de cette partie de travail est de fournir des mesures de protection et sécurité contre les phénomènes d'instabilité par l'évaluation du comportement dynamique approfondi réalisé sur une turbine à gaz et pouvoir établir par la suite dans le chapitre suivant une stratégie de diagnostics efficace à ce type de machine tournante. La démarche suivie sera la proposition d'un système de détection de vibration basée sur le développement des outils des neurones formels, connectés entre eux selon la configuration adoptée à la turbine à gaz étudiée. Les résultats obtenus permettent de mieux gérer les défaillances causées par les vibrations et montrer l'efficacité des réseaux de neurones artificiels comme outils de calcul très puissants dans la modélisation des systèmes dynamiques complexes.

En effet, en 2016 Amozegar M. et Khorasani K. dans [3] ont proposé des identificateurs basés sur des réseaux neuronaux dynamiques pour l'identification et l'isolation des défaillances appliqués à une turbine à gaz, Hamid Asgari et al. dans [15] ont testé des modèles autorégressive non linéaire avec entrée exogène externe (NARX) pour la modélisation de l'étape de démarrage d'une turbine à un seul arbre, Marjani A. et Baghmolai A.M. dans [18] ont fait une modélisation analytique et numérique du réseau de transport de gaz avec une comparaison des résultats obtenus par les neurones formels (ANN) et le système de concept flou (FIS), Grzegorz Nowak et Andrzej Rusin dans [14] ont utilisé les neurones formels pour contrôler le processus de chauffage d'une turbine à vapeur et Nadji Hadroug et al. dans [20] ont proposé un système de détection des défauts dans une turbine à gaz en utilisant des systèmes d'inférence flou basés sur un réseau adaptatif hybride pour contrôler leur comportement dynamique. Ces travaux ont été réalisés et se sont imposés par l'intérêt soutenu des réseaux de neurones artificiels pour plusieurs investigations sur les machines tournantes.

Dans le cadre de la mise en pratique de cette procédure de supervision, utilisant les réseaux de neurones artificiels, ce chapitre propose une stratégie de détection des dysfonctionnements affichants une turbine à gaz de type GE MS 3002 basée sur une modélisation autorégressive non linéaire dynamique avec entrée exogène externe (NARX). Dans le but de surveiller cette turbine à gaz, un choix préalable d'un certain nombre d'indicateurs issus de mesures et établis en permanence au cours du fonctionnement à été faite.

III.2. Turbines à gaz

Dans plusieurs applications industrielles, il existe principalement deux types de turbine à gaz; Turbine mono-arbre et turbine bi-arbre. Cette classification est selon le nombre des arbres utilisée dans ces turbines à gaz [18, 21, 37, 43]. D'après le mode de construction il existe plusieurs types de turbines à gaz qui se compose d'un dispositif de démarrage, d'accessoires, d'un compresseur axial, d'un processus de combustion et d'une turbine d'énergie et le système d'échappement.

En outre, dans chaque cas d'application envisagé, le constructeur de la turbine à gaz ou le fournisseur du groupe devra préciser les performances attendues dans les différentes conditions de fonctionnement prévues.

III.3. Vibrations d'une turbine à gaz

L'analyse vibratoire prend actuellement une place très importante, dans l'industrie des machines tournante. Où, les vibrations induites par des machines en fonctionnement, fournissent des informations sur leur état et leur comportement. En effet, les paliers dans les turbines à gaz sont des organes sensibles à ces phénomènes vibratoires. Ces derniers ont fait le but de plusieurs applications et études dans la littérature industrielle. Ces sont des éléments très susceptibles de subir des défauts de vibration, provoquant rapidement leurs détérioration.

La compréhension du comportement vibratoire d'une turbine est un enjeu industriel dont l'importance n'a cessé d'augmenter durant ces dernières années. La déformation dynamique non maîtrisée d'une structure (par exemple les boucliers et les ailettes d'une turbine) peut entraîner un vieillissement prématuré des composants, ou encore des nuisances sonores et vibratoires inacceptables.

Ce travail propose l'analyse du comportement dynamique vibratoire d'une turbine à gaz, basée sur le développement des outils des réseaux de neurones artificiels. Utilisant une analyse du signal vibratoire avec une approche neuronale cela va permettre d'intervenir à temps qu'en présence d'éléments défectueux (balourd désalignement, fracture, fissuration ou lubrification), et ainsi minimiser le temps de réparation sur la machine examinée. Cela ne se réalise qu'avec une stratégie de diagnostic fiable et facilement à implémenté, malgré la complexité de cette machine tournante.

III.3.1. Modélisation de vibrations de turbine à gaz

Comme tout mouvement, les vibrations peut être quantifiées par trois quantités fondamentales [6, 12, 17, 22 et 23]. Le déplacement et la vitesse de ce mouvement et l'accélération expérimentés pour faire ce mouvement. Le modèle considéré la turbine comporte deux entrées: la température ambiante et le débit massique du carburant, donnée par les équations suivantes:

$$\dot{m}_c = \sqrt{\Delta P} \cdot \frac{1}{2} \rho \mu^2 = \frac{\sqrt{\Delta P}}{k} \Rightarrow \dot{m}_c = \frac{1}{k} \sqrt{\Delta P} \quad (\text{III.1})$$

L'écoulement de débit d'air \dot{m}_a est donné par:

$$\begin{cases} \dot{m}_a = k'(P_2 - P_1) \\ \dot{m}_a = k'(PCD - P_{atm}) \end{cases} \quad (\text{III.2})$$

Il faut contrôler la combustion de la turbine à gaz en régulant le rapport entre le rendement f donné par:

$$f = \frac{(T_3 - T_2)}{\eta_b CV + T_3} \quad (\text{III.3})$$

Des capteurs sont installés sur la turbine à gaz pour fournir les comportements dynamiques ; de la turbine haute pression HP à grande vitesse d'arbre (NGP), et la vitesse d'arbre (TNP) de la turbine à basse pression BP et la température des lames de turbine. Ces mesures peuvent être utilisées pour fournir différentes données d'entrée / sortie pour la commande des vibrations dans une boucle fermée. Pour cela, le mouvement harmonique et écrit par l'équation de vibration:

$$x(t) = A \sin(\omega t + \varphi) \quad (\text{III.4})$$

Avec : ω est la pulsation propre de vibration, φ est la phase et A est l'amplitude de vibration et l'unité utilisée est en micromètres (μm).

Pour les vitesses de vibration $v(t)$ et l'accélération de vibration $a(t)$ sont obtenus en dérivons le déplacement de vibration, donnée par:

$$\begin{aligned} v(t) &= \frac{dx(t)}{dt} = A\omega \cos(\omega t + \varphi) \\ \Rightarrow a(t) &= \frac{dv(t)}{dt} \end{aligned} \quad (\text{III.5})$$

Universellement, les unités utilisées sont en millimètres par seconde (mm / s). Il en résulte des équations (6) et (7) la suite interconnexion entre les modules:

$$\begin{aligned} |X| &= \frac{|v|}{w} = \frac{|A|}{w^2} \\ |v| &= |X|.w = \frac{|A|}{w} \\ |A| &= |v|.w = |X|.w^2 \end{aligned} \quad (III.6)$$

L'équation (III.6) met en évidence l'importance du choix des grandeurs physique aux données de mesures et de suivi de la turbine à gaz. Par rapport à un modèle de mesure de vitesse, la mesure de déplacement aura lieu pour des effets d'affaiblir les composantes de haute fréquence et moyenne et d'amplifier les composantes de basse fréquence. Toutefois, le mesure en mode d'accélération aura lieu pour des effets de réduire les composantes de basse fréquence et amplifier les composantes haute fréquence [4, 7, 9 et 11].

III.3.2. Vibrations des paliers de turbine

Les vibrations des paliers de turbine est modélisé d'une manière générale, par le quantité de travail de ces éléments δW_p des effets extérieures appliquée sur l'arbre, comme il est montré la Figure III.1, donnée par :

$$\delta W_p = -K_{xx}u\delta_u - k_{xz}w\delta_u - k_{zz}u\delta_w - k_{zx}u\delta_w - c_{xx}\dot{u}\delta_u - c_{xz}\dot{w}\delta_u - c_{zz}\dot{w}\delta_w - c_{zx}\delta_w \quad (III.7)$$

Avec, k_{xx} , k_{zz} , C_{xx} et C_{zz} sont les rigidités, k_{xz} , k_{zx} , C_{xz} et C_{zx} sont les rigidités et les amortissements.

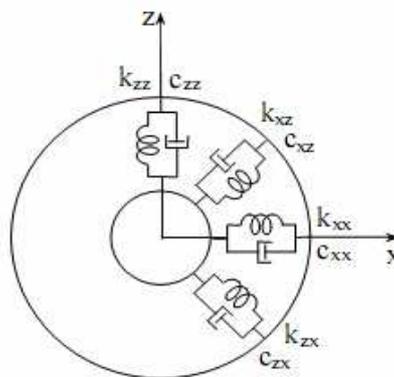


Figure III.1 : Amortissement et raideurs de palier

III.3.3. Défauts de désalignement

En réalité industrielle, on peut modéliser le défaut d'alignement par les trois modes axial, angulaire et radiale, pour chacun desquels on définit une rigidité, comme il est montré sur les Figures III.2.A, III.2.B et III.2.C.

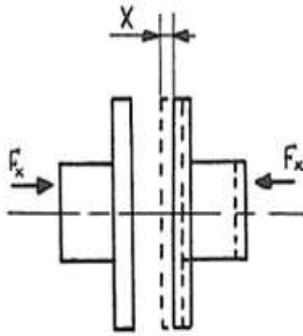


Figure III.2.A : Mode axiale

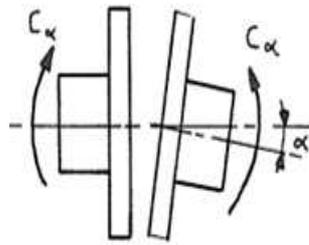


Figure III.2.B : Mode angulaire

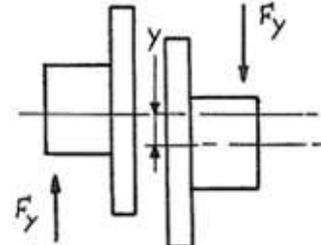


Figure III.2.C : Mode radiale

III.3.4. Phénomène de balourds

Pour toutes machines tournante, il existe un déséquilibre résiduel qui va se traduire, sur le spectre de signaux vibratoire, comme il est montré sur la Figure III.3, par la variation d'une partie de signal de base synchronise avec la fréquence de vitesse de rotation. Sur un plan radial le déséquilibre induit des vibrations dont le spectre montre une partie d'amplitude prépondérante à la fréquence de vitesse de rotation du rotor. Pratiquement, il y a deux catégories de phénomène de balourds:

- **Balourd statique**

Les paliers supportant le rotor vont subir, en même temps, l'effort centrifuge dû au déséquilibre. Il n'y aura donc aucun déphasage entre les mesures prises au même point sur les paliers.

- **Balourd dynamique**

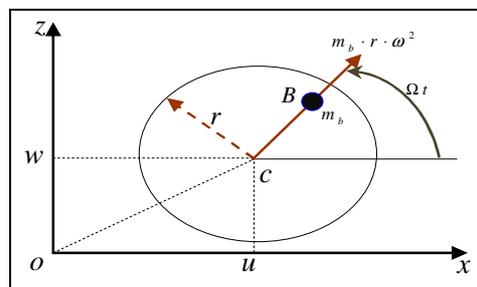


Figure III.3 : Force centrifuge due au Balourd

Pratiquement, les équations de phénomène de balourd sont présentés par :

$$\begin{aligned} x(t) &= u_B + d \cos \Omega t & \Rightarrow & \frac{dx(t)}{dt} = \dot{u}_B - d \Omega \sin \Omega t \\ z(t) &= \omega_B + d \sin \Omega t & \Rightarrow & \frac{dz(t)}{dt} = \dot{\omega}_B + d \Omega \cos \Omega t \end{aligned} \quad (III.8)$$

Son énergie cinétique est alors calculer par :

$$T_{Bal} = \frac{1}{2} m_b \left(\dot{u}_B^2 + \dot{\omega}_B^2 \right) + \Omega^2 d^2 + 2 \Omega d \dot{u}_B \sin \Omega t - 2 \Omega d \dot{\omega}_B \cos \Omega t \quad (III.9)$$

Le terme $\Omega^2 d^2 / 2$ est un terme constant

La densité de phénomène de balourd est approximée par :

$$T_{Bal} \approx m_b d \Omega \left(\dot{u}_B \sin \Omega t - \dot{\omega}_B \cos \Omega t \right) \quad (III.10)$$

En introduisant les coordonnées généralisées, on trouve la représentation de phénomène de Balourd suivante :

$$T_{Bal} \approx m_b d \Omega \left[\begin{aligned} & \left(\dot{A}_u Y_B^3 + \dot{B}_u Y_B^2 + \dot{C}_u Y_B^2 + \dot{D}_u \right) \sin \Omega t - \\ & \left(\dot{A}_w Y_B^3 + \dot{B}_w Y_B^2 + \dot{C}_w Y_B^2 + \dot{D}_w \right) \cos \Omega t \end{aligned} \right] \quad (III.11)$$

III.4. Danger et remèdes de vibrations des turbines.

Les vibrations à l'état stationnaire ou en régime transitoire peuvent engendrer une détérioration du système infiniment plus vite que les seules considérations de force. Les manifestations usuelles de vibrations sont :

- Phénomène de fatigue,
- Bruit,
- Usure,
- Phénomènes sismiques.

La Figure III.4 montre l'endommagement sur le démarreur pneumatique du système de démarrage d'une turbine à gaz d'une station de compression de gaz installé au sud de l'Algérie, elle était découverte après démontage et suite à la détection d'une vibration accélérométrique importante provoquant l'arrêt de cette turbine.



Figure III.4: Endommagement du démarreur pneumatique de la turbine à gaz

III.5. Surveillance de vibrations

Dans le but de surveillance des fatigues et des endommagements dans les structures des machines tournants, on propose dans cette partie du travail d'utiliser les méthodes de réseaux de neurones artificiels. En effet, les problèmes liés à la détection de défauts sur les organes de machines peuvent être résolue par les techniques classiques. Néanmoins, il existe d'autre problèmes liés aux vibrations ou les techniques classiques n'ont pas adaptées et aptes pour soulever ce types de problèmes, qui est le cas pour les vibrations des turbines à gaz.

Dans la réalité industrielle, la protection de vibration adoptée est basée sur un système de surveillance des vibrations à recours des sondes de proximité, des accéléromètres et des transducteurs pour surveiller les vibrations et l'accélération, ou les niveaux de vibration et d'accélération peuvent être observés sur le terminal. Le système de surveillance des vibrations est un sous-système de contrôle commande. Il utilise des sondes pour mesurer le déplacement. De ces mesures, des données de vibration radiales et axiales sont élaborées. Les sondes sont activées et mesurent la tension en système de contrôle commande d'entrefer entre la sonde et une surface mobile.

Les sondes mesurent le déplacement à haute fréquence, le système de surveillance des vibrations utilise des détecteurs sismiques pour mesurer la vitesse ou l'accélération. Les dispositifs sismiques, également appelés accéléromètres, mesurent les déplacements à fréquence plus basse, comme il est montré sur l'organigramme de supervision des vibrations de la turbine de la Figure III.5.

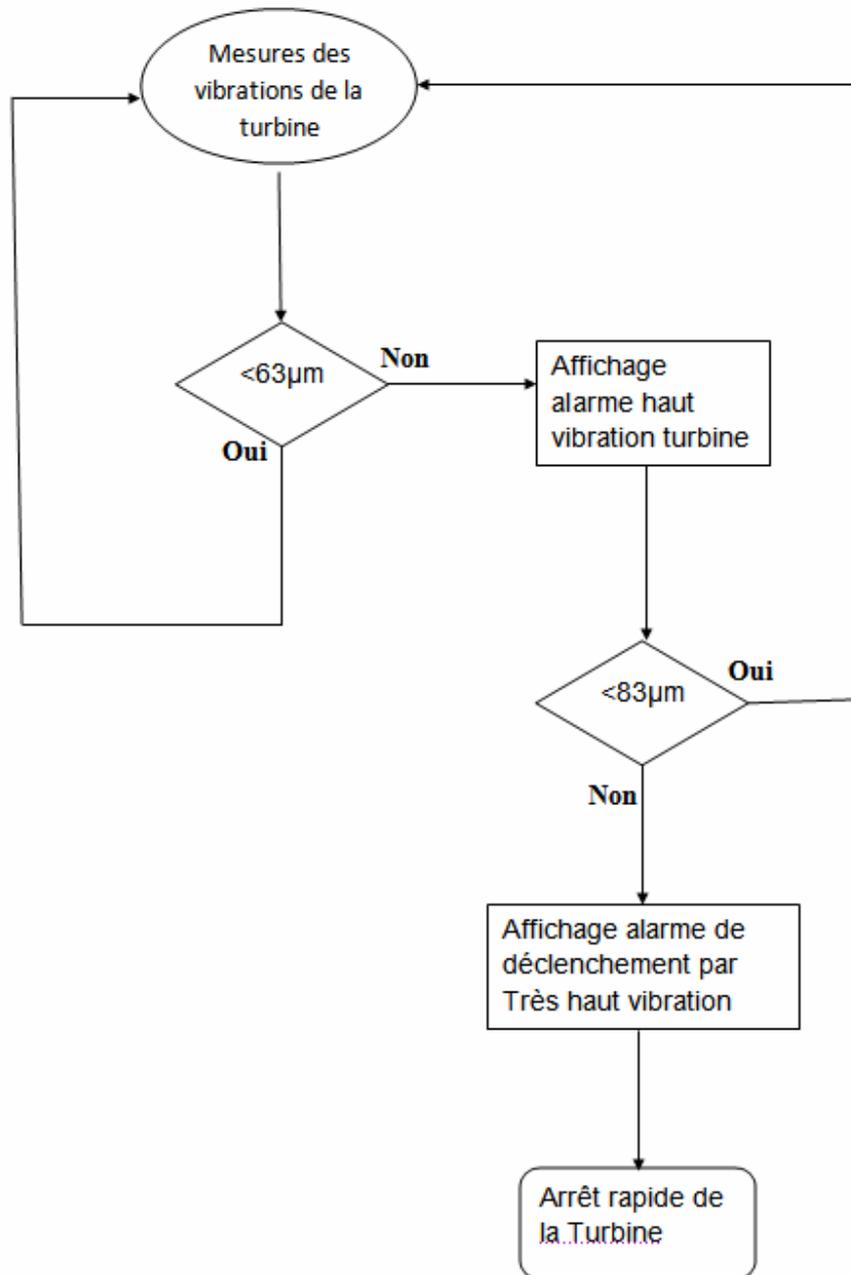


Figure III.5 : Organigramme de supervision de vibrations de la turbine

III.5.1. Indicateurs de surveillance de vibrations

Les vibrations périodiques de type impulsionnel sont les références des forces appliquées sur la machine, où les indicateurs de surveillance de vibrations sont :

1. Indicateurs généraux (spectres) ;

2. Indicateurs spécifiques.

III.5.2. Système de supervision à base d'intelligence artificielle

L'Intelligence Artificielle (IA) est définie identiquement à « la construction de programmes informatiques qui s'adonnent à des tâches qui sont, pour l'instant, accomplies de façon plus satisfaisante par des êtres humains car elles demandent des processus mentaux de haut niveau tels que : l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique » [7, 8].

D'une façon pratique, une technique relevant d'intelligence artificielle est défini par :

- Facilité à manier les informations symboliques et les informations numériques ;
- Capacité de résolution d'un problème dont on ne connaît pas à priori d'algorithmes classiques conduisant à une solution ;
- Représentation des connaissances qui établit un lien entre le monde extérieur et un système symbolique qui permet de raisonner ;
- Capacité de fournir une solution à un problème, même si les données disponibles à l'origine sont incomplètes ;
- Capacité à prendre en compte des informations contradictoires ou entachées d'incertitudes ;
- Capacité d'apprentissage qui représente l'intelligence de ce type d'outil;
- Séparation des connaissances de leur mécanisme d'exploitation.

III.6. Supervision par réseaux de neurones artificiels

Pour mettre au point une telle procédure de supervision, la première étape consiste à mettre au point un modèle du système. C'est une étape très délicate, car des erreurs ou des simplifications trop importantes risquent de diminuer considérablement les performances du système de diagnostic. Selon la connaissance du système dont on dispose, sa complexité et sa nature, le type de modèle sera différent : modèle paramétrique ou non paramétrique, modèle continu, discret, numérique... [12]

Une fois le modèle validé, la procédure de diagnostic en elle-même comporte quatre phases:

- Génération de résidus, grandeurs sensibles aux défauts ;
- Détection de défauts éventuellement présents, par l'analyse des résidus ;
- Localisation et l'identification du type de défaillance ;
- Isolation.

III.7. Résultats d'investigation des réseaux de neurones pour la détection de vibrations

La turbine à gaz étudié contient quatre paliers et leurs signaux transmettent au salle contrôle et au IMH (Interface Homme Machine) par des transmetteurs qui prennent les signaux des capteurs de vibration qui transmettent le signal mécanique par un signal électrique, ces signaux représentent l'état des arbres de la turbine.

Ces signaux peuvent être (balourd, désalignement,... etc) ou en état normale, et le système de contrôle commande possède un seuil défini par le constructeur, une fois l'amplitude de l'un de ces signaux dépasse ce seuil, le système de contrôle commande intervient par l'arrêt d'urgence (Emergency Shut Down). A cet effet, notre objectif vise à injecter les signaux réels des paliers et injecter dans un système intelligent basé sur le réseau de neurones artificiel dans le but d'avoir la probabilité d'utiliser le réseau de neurones comme un processus de contrôle parallèle avec le processus de contrôle commande de la turbine à gaz étudiée.

La turbine à gaz étudiée possède quatre paliers, chacun d'eux délivre des signaux vibratoires (axiale et radiale) sont présentés, et pour diagnostiquer et détecter si ces signaux génèrent des vibrations dépassant l'intervalle de tolérance de constructeur. Nous injectons ces signaux dans un réseau de neurones avec différentes architectures pour avoir la capacité de notre réseau à détecter et localiser les vibrations apparues dans notre système.

La procédure de détection de vibrations montrée sur la Figure III.6, propose trois étapes fondamentales pour un système de turbine à gaz utilisant les démarches suivantes:

- La première étape consiste à déterminer le choix du modèle neuronal,
- La deuxième phase consiste à générer les résidus,
- La troisième étape est celle de la prise de décision vis-à-vis des défauts localisés.

Avant de mettre en œuvre ces étapes, nous allons développer le modèle neuronal utilisé pour l'identification des vibrations dans le système de turbine à gaz.

Le choix du modèle neuronal à apprentissage pour l'identification du modèle comportemental dynamique de turbine dépend strictement de la complexité du modèle d'état traduisant le fonctionnement sain ou défaillant de la turbine [5, 9, 15, 24].

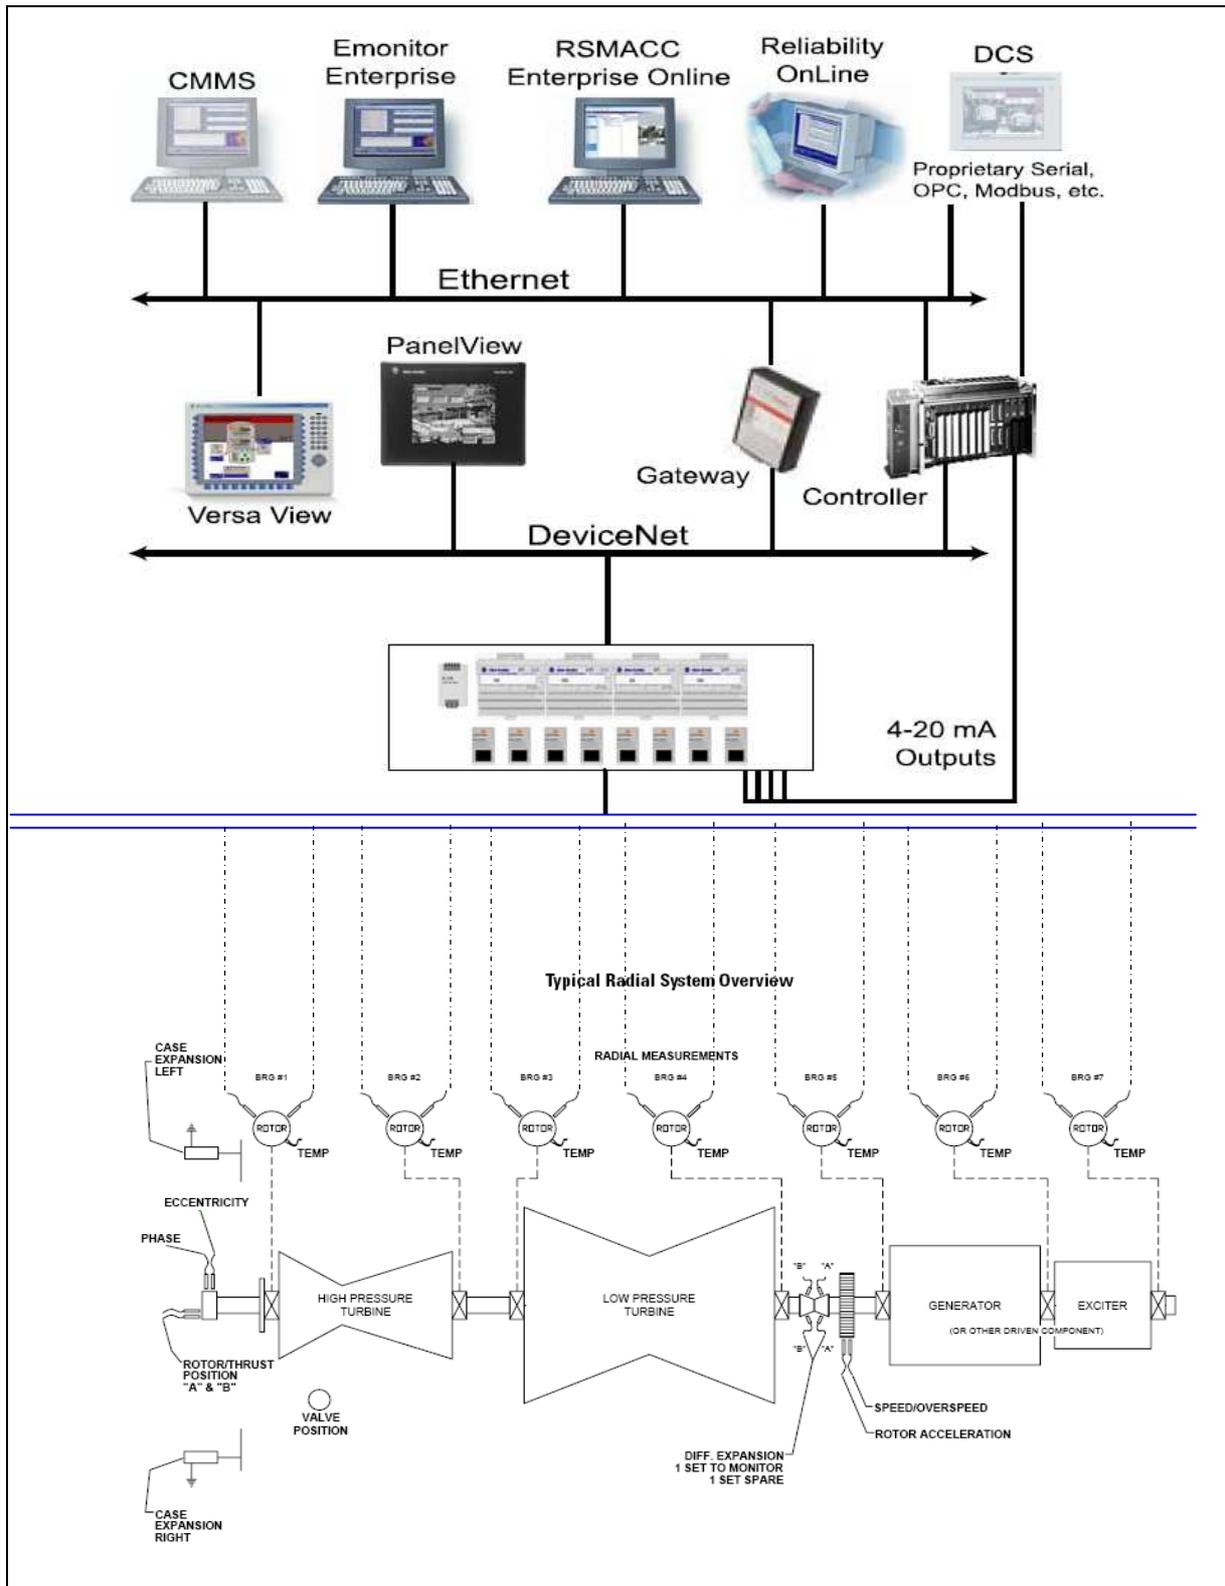


Figure III.6: Système supervision de turbine à gaz

III.7.1. Choix du modèle neuronal

Pour générer les résidus qui ont a besoin dans le système de diagnostic; il est obligé à nous modéliser le système industriel, comme il est montré sur la Figure III.7, pour y arriver on a choisis les réseaux de la forme de « Feed-Forward » et pris le model multicouche « MLP ».

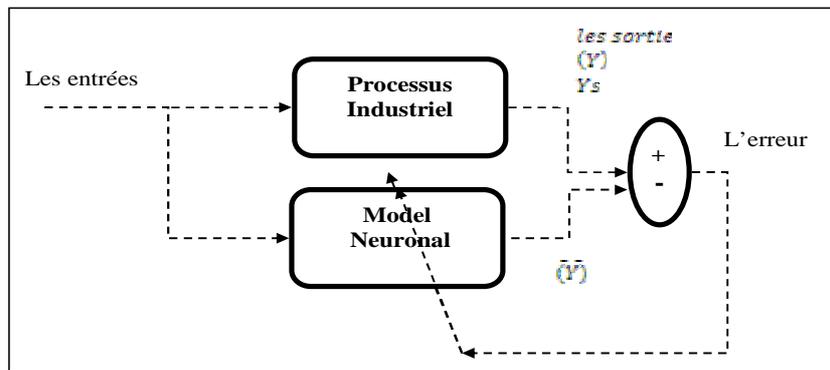


Figure III.7: Schéma général de la modélisation

L'algorithme qui nous permet de sélectionner le modèle neuronal robuste, en identification, est recherché selon les étapes suivantes :

- Connaissance approfondie sur le système à identifier.
- Le choix des entrées et du sorties du modèle neuronal.
- Détermination du comportement interne du modèle neuronal.
- Choix des fonctions d'activation.
- Choix de la précision et du nombre d'itération.

Dans notre RNA nous avons utilisé les variables (l'accélération, la vitesse de rotation) qui sont utilisées car elles sont les plus représentative des défauts (leurs allures varient considérablement en cas d'application d'un défaut). D'autre part, leurs mesures sont accessibles par des capteurs qui fournissent leurs grandeurs physiques.

Le modèle neuronal obtenu pour les différentes variables de la turbine à gaz examinée est représenté sur les Figures III.8 jusqu'à l'III.19. La Figure III.8 montre la réponse du modèle de la variation de vibration de la vitesse de la turbine en (mm / s), la Figure III.9 montre la réponse du modèle de la variation de la vitesse de la turbine, la Figure III.10 présente la variation de la sortie de la vanne de la chambre de combustion, la Figure III.11 présente la variation de la pression de la chambre de combustion, la Figure

III.12 montre la variation de la température de sortie de la chambre de combustion, la Figure III.13 montre la réponse de la commande de la vanne de la chambre de combustion, la Figure III.14 donne la position d'ouverture de la vanne de la chambre de combustion, et finalement la Figure III.15 présente la variation de la température d'échappement de la turbine.

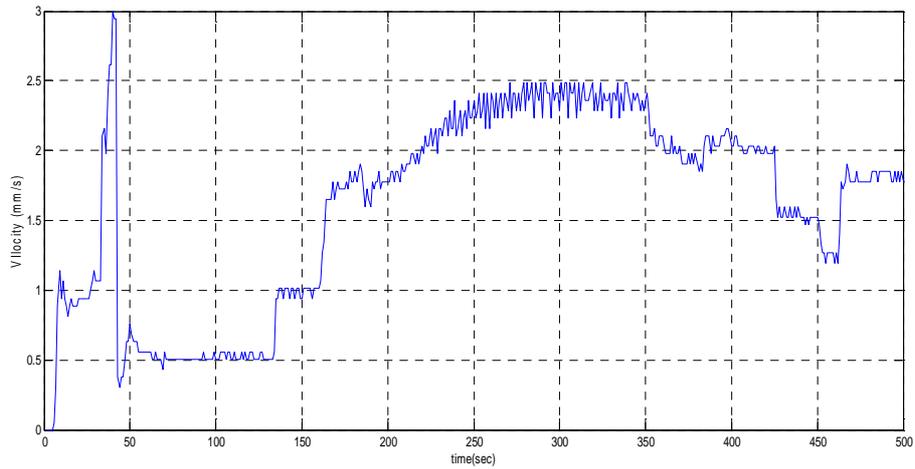


Figure III.8: Réponse du modèle de la variation de la vibration de la vitesse de la turbine mm / s

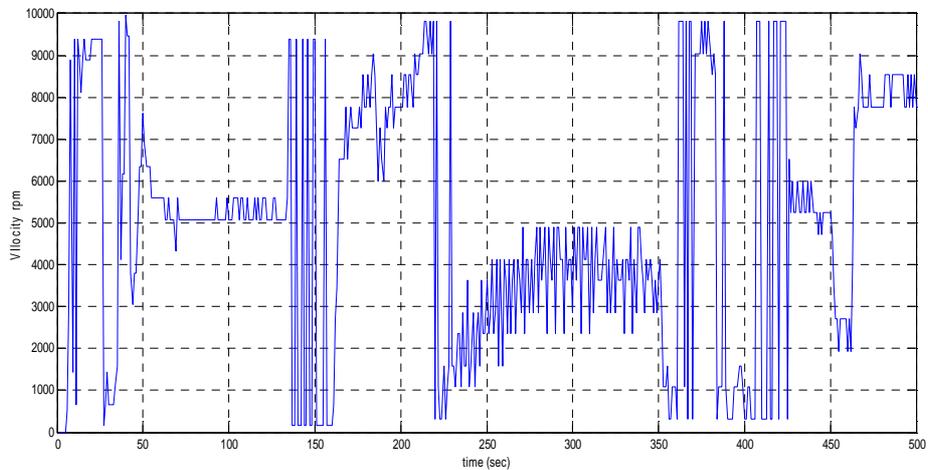


Figure III.9: Réponse du modèle de la variation de la vitesse de la turbine

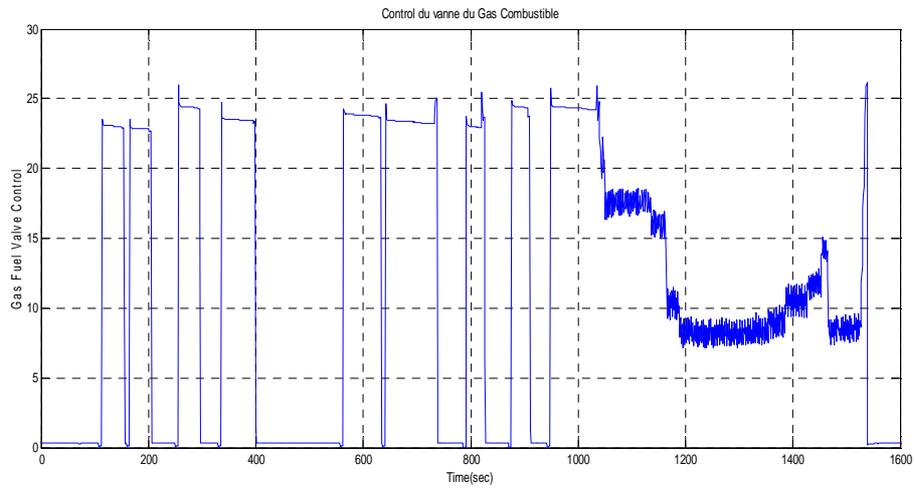


Figure III.10: Variation de la sortie de la vanne de la chambre de combustion

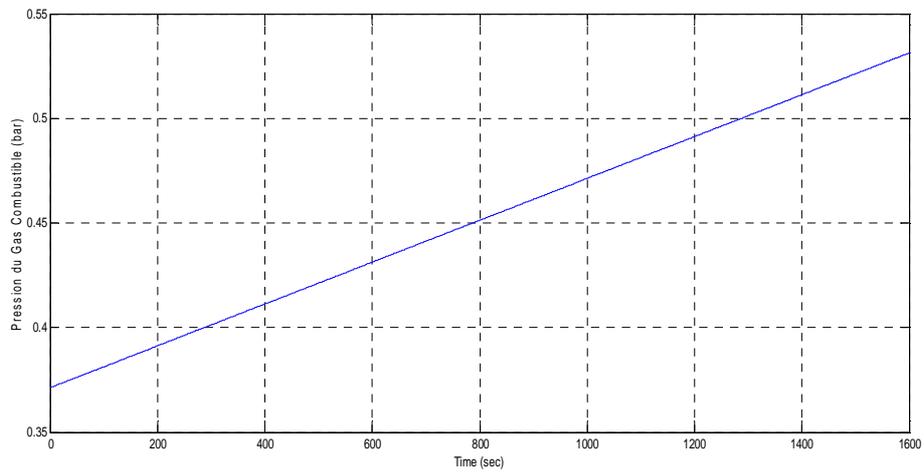


Figure III.11: Variation de la pression de la chambre de combustion

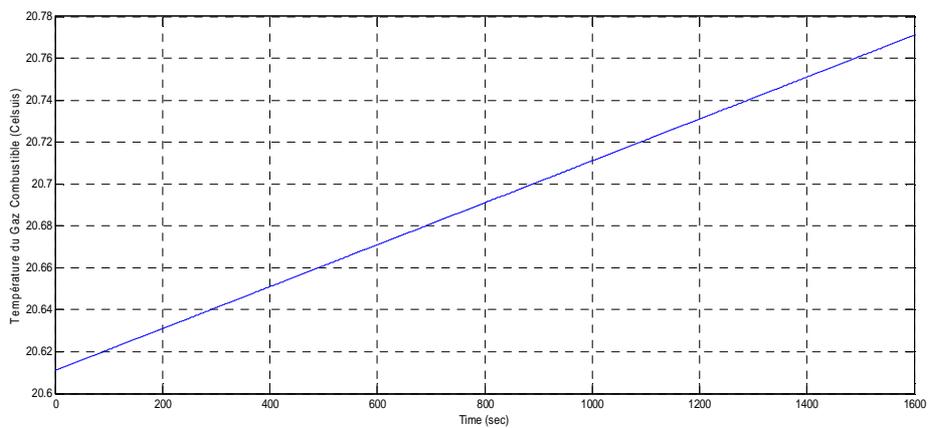


Figure III.12: Variation de la température de la chambre de combustion

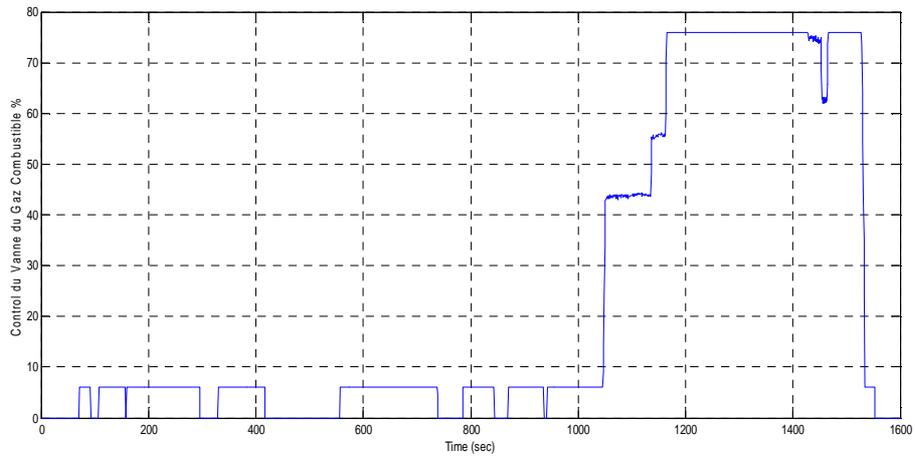


Figure III.13: Réponse de la commande de la vanne de la chambre de combustion

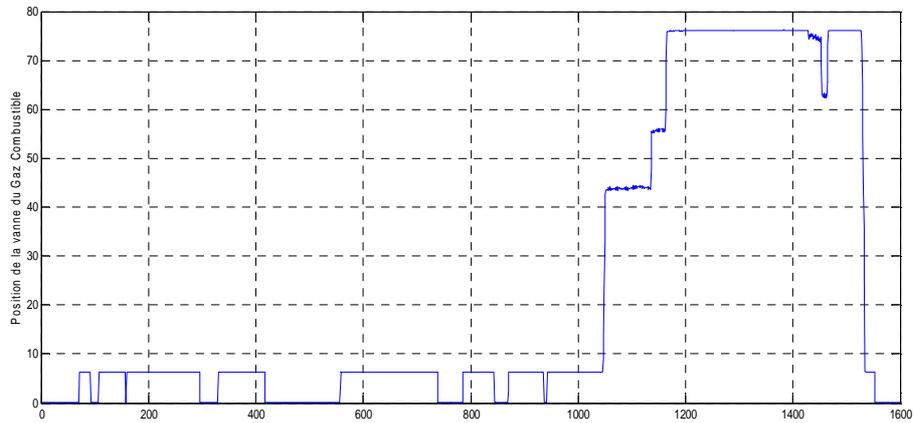


Figure III.14: Position d'ouverture de la vanne de la chambre de combustion

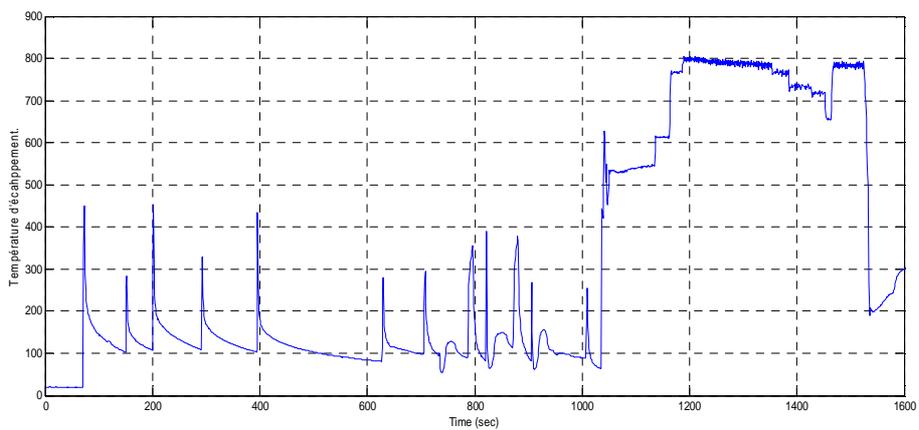


Figure III.15: Variation de la température de sortie de turbine examinée

Le système de surveillance de la turbine à gaz à deux arbres réalisé dans ce travail est basé sur les variables d'entrées et des sorties de cette machine tournante. Ces variables sont utilisées pour la modélisation de la turbine à gaz d'une part et d'autre par permet aussi d'assurer un exploitation en mode dégradé en présence de défauts de vibrations. La Figure III.16 montre la réponse de vibration de la vitesse axial de la turbine à haute pression, la Figure III.17 montre la réponse de la vibration de la vitesse radiale de la turbine à haute pression, la Figure III.18 illustre la variation de la vibration de vitesse axiale de la turbine à basse pression alors que la Figure III.19 représente la variation de vibration de la vitesse radiale de la turbine à basse pression

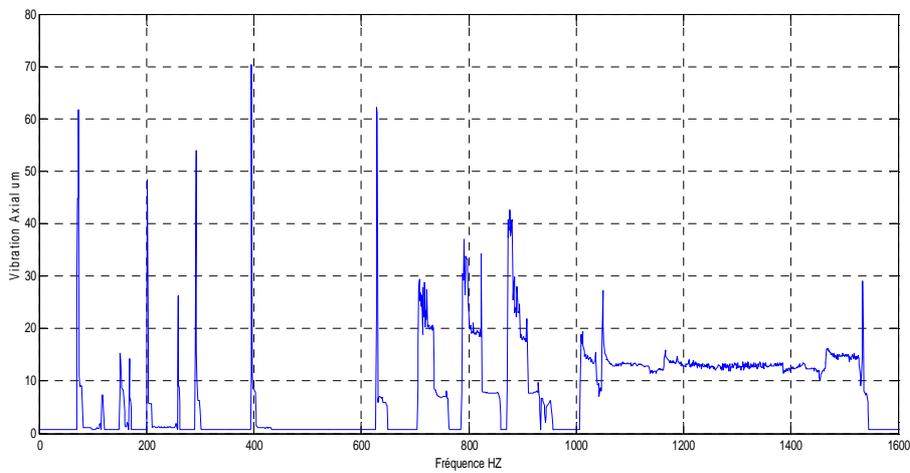


Figure III.16: Vibration de la vitesse axiale de la turbine à haute pression

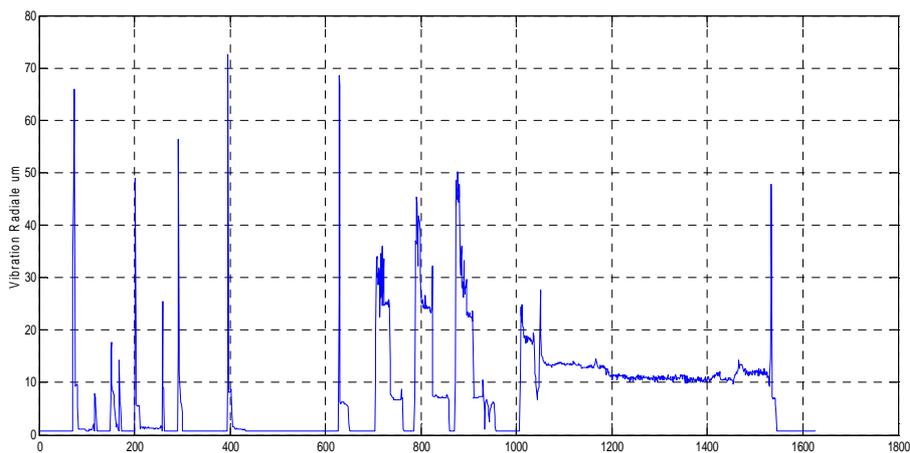


Figure III.17: Vibration de la vitesse radiale de la turbine à haute pression

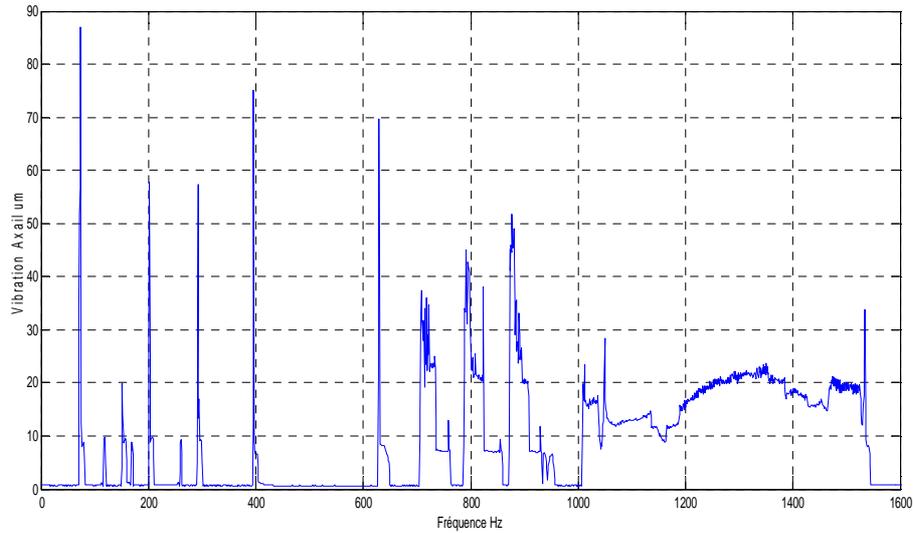


Figure III.18: Vibration de la vitesse axiale de la turbine à basse pression

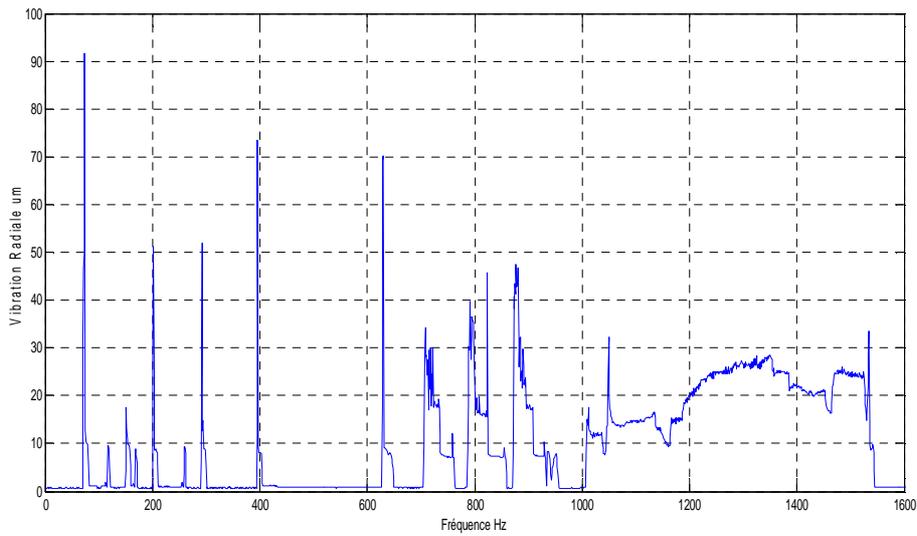


Figure III.19: Vibration de la vitesse radiale de la turbine à basse pression

D'après les résultats obtenus, les réponses issues de données vibratoires de la machine examinée sont très riches, la modélisation du système de la turbine à permet d'exprimer des relations analytiques entre les différentes variables du système physique. Dès lors, nous allons exploiter la redondance analytique afin de générer des résidus.

Certaines variables du système décrit au paragraphe précédent correspondent à des variables connues, grâce aux mesures effectuées sur le processus engendrent une redondance informationnelle. Vérifier la cohérence de cette relation de redondance revient à générer des indicateurs de défaut qui seront utilisés pour surveiller le fonctionnement de turbine à gaz examinée. Dans un souci de clarté la stratégie de détection de la vibration à base de réseau de neurones dynamique proposées. Les Figures III.20 jusqu'au III.27 montrent la détection des vibrations axiales et radiales des paliers n° 01, 02, 03 et 04 de la turbine à gaz examinée.

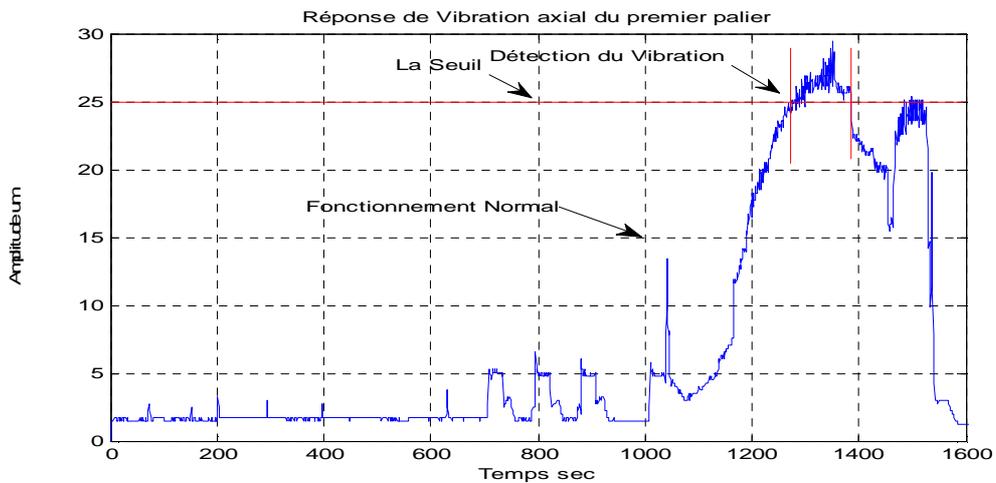


Figure III.20: Détection de vibrations axiales de palier n° 01

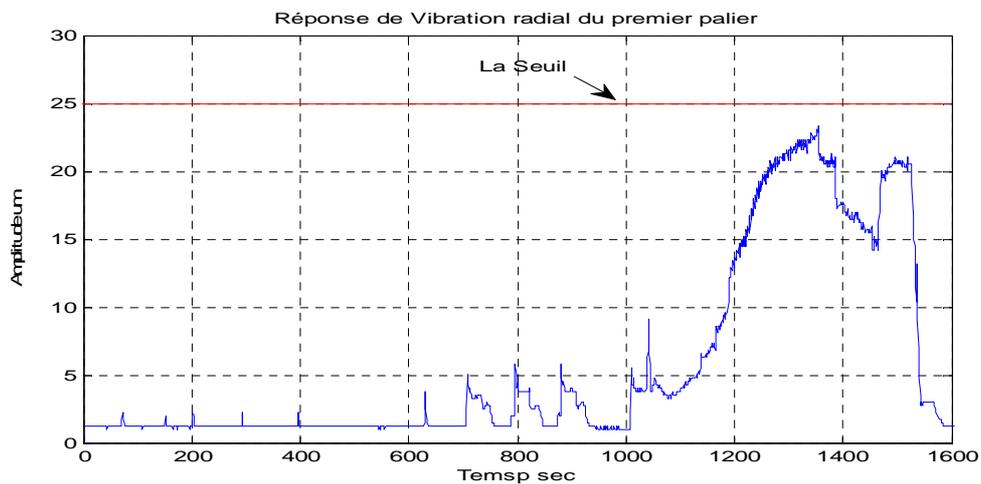


Figure III.21: Détection de vibrations radiales de palier n° 01

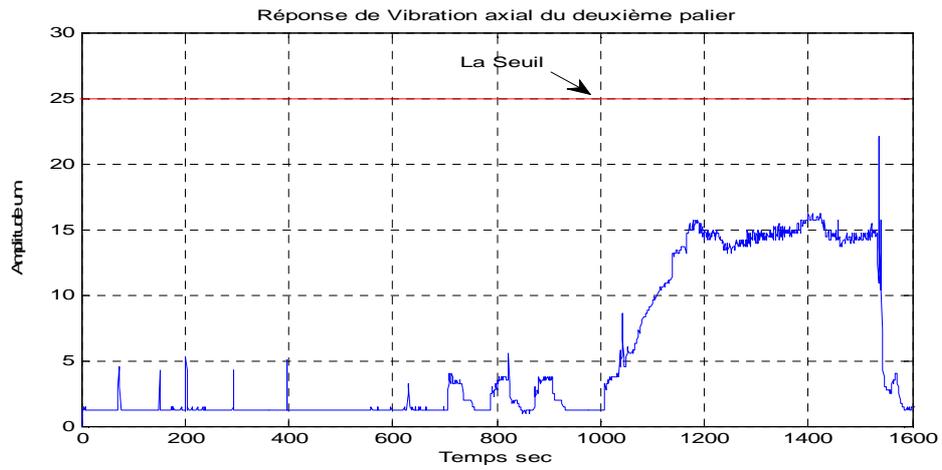


Figure III.22: Détection de vibrations axiales de palier n° 02

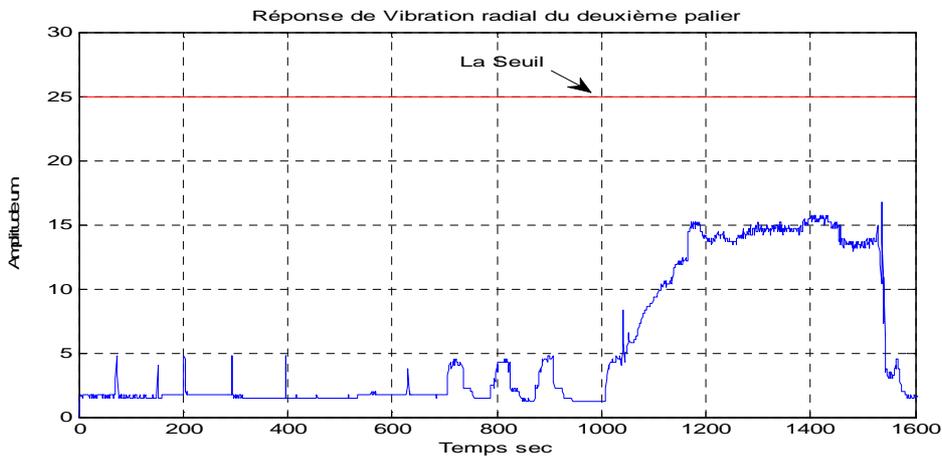


Figure III.23: Détection de vibrations radiales de palier n° 02

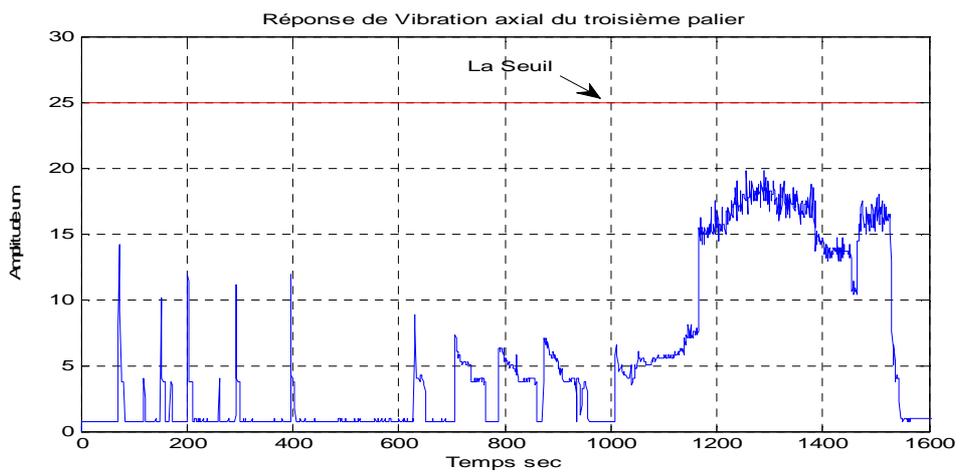


Figure III.24: Détection de vibrations axiales de palier n° 03

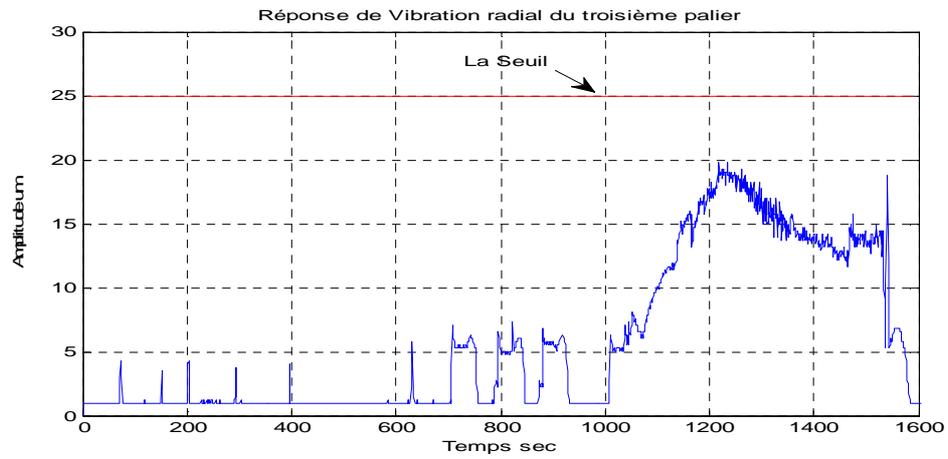


Figure III.25: Détection de vibrations radiales de palier n° 03

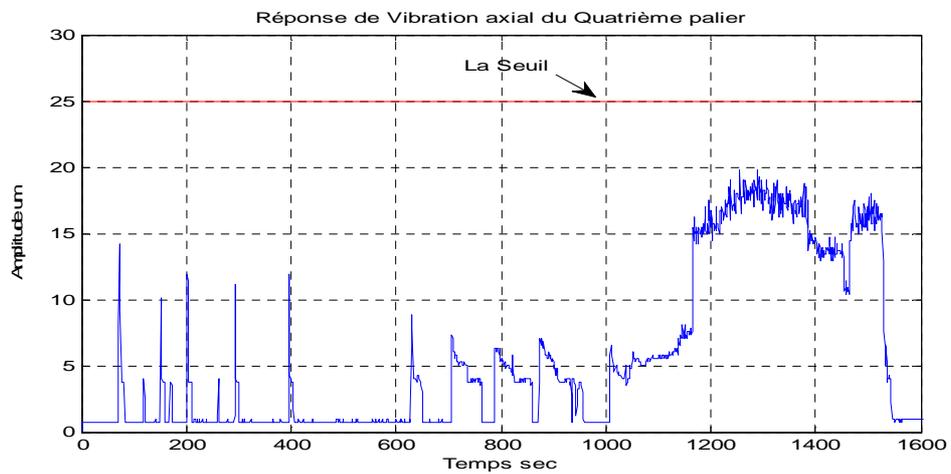


Figure III.26: Détection de vibrations axiales de palier n° 04

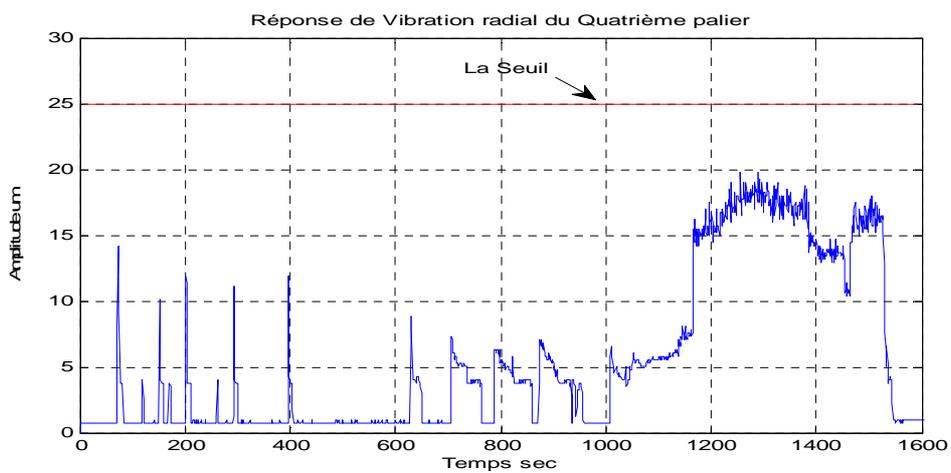


Figure III.27: Détection de vibrations radiales de palier n° 04

D'autres tests de validation ont été réalisés par un réseau de neurones dynamique et qui consiste à injecter les quatre réponses vibratoires ainsi que vérifier quel palier est généré des vibrations dépassées le seuil de constructeur. En plus le réseau doit modifier chaque fois leur architectures pour suivre et minimiser le maximum les erreurs entre le signal réel et le signal neuronale, comme il est montré sur la Figure III.28.

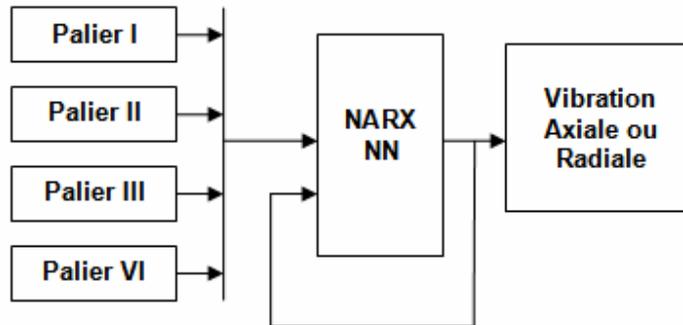


Figure III.28. Identification et localisation de la vibration utilisant les réseaux de neurones dynamique

Ces tests de validation ont pour double objectif, le premier c'est pour détecter quel palier est généré des vibrations soit axiales ou radiales a dépassé le seuil, alors que le deuxième a pour objectif la localisations du palier défectueux. La Figure III.29 montre l'apport de la méthode d'identification et de la localisation de la vibration axiale du premier palier de la turbine examinée.

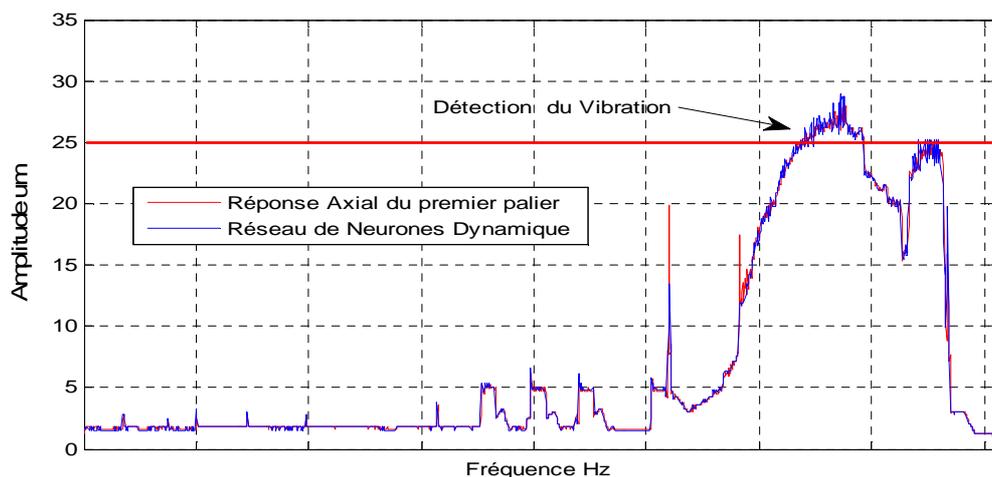


Figure.III.29: Détection et localisation de la vibration axiale du premier palier

Le réseau de neurones dynamique est caractérisé par une seule élément cachée avec 15 neurones cachés avec une activation de type simgoide et une seul élément de sortie avec une activation linéaire.

Notre but essentiel est de minimiser le maximum l'erreur quadratique moyenne jusqu'à d'avoir les deux courbes identiques. La Figure III.30 représente l'erreur quadratique moyenne de tests de validation.

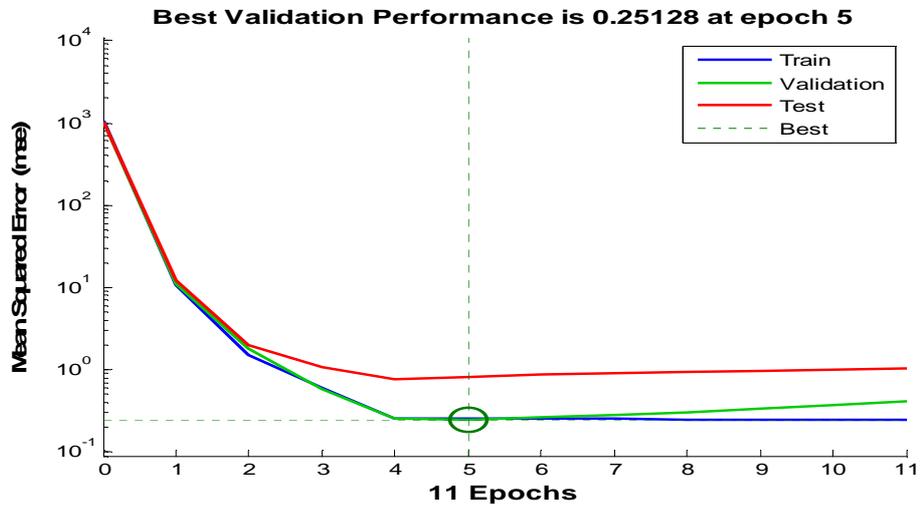


Figure III.30: Erreur Quadratique moyenne

Un autre test de robustesse est appliqué sur le réseau dynamique pour confirmer la capacité du réseau à suivre l'allure du signal vibratoire. Il est présenter par Les valeurs de régression R mesurant la corrélation entre les réponses du réseau (entraînement, test, et validation) et les cibles, comme il est montré sur la Figure III.31.

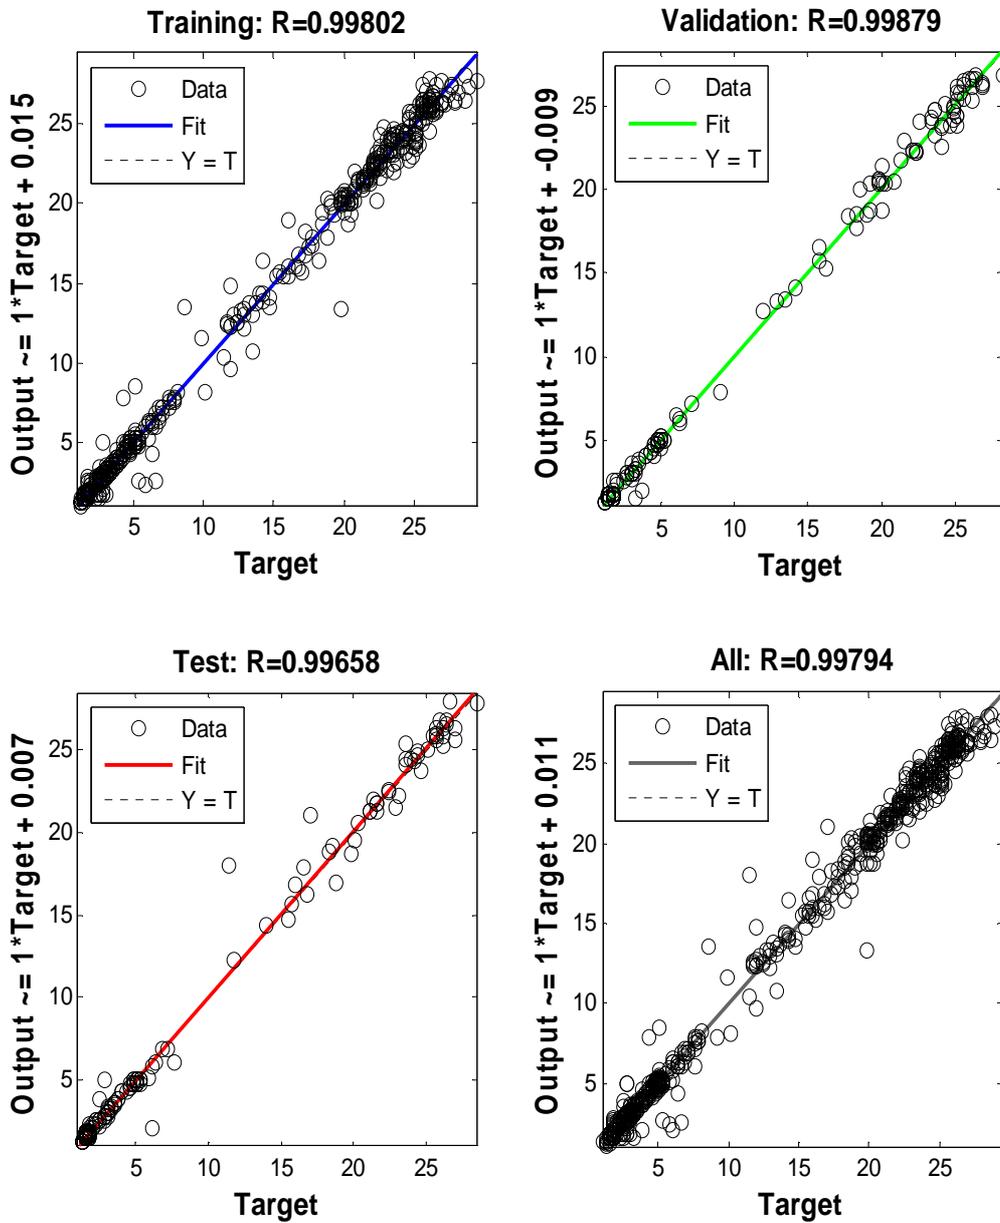


Figure III.31: Corrélation entre le réseau et la réponse vibration

Les résultats obtenus indiquent des diagnostics et contrôles fiables, et surtout que la baisse du taux de généralisation revient aux transitions entre les fonctionnements normaux et anormaux de la machine.

III.8. Conclusion

Dans cette partie, nous avons appréhendé les vibrations de la turbine à gaz dans le but de proposer une stratégie de leur détection. Un modèle comportemental a ainsi été utilisé en tenant compte de sources de vibrations affectants ce type de machines tournantes. Le modèle développé dans ce travail simule le comportement dynamique de la turbine à gaz, tournant à haute vitesse, destiné à conduire un compresseur centrifuge utilisé dans le transport de gaz naturel. Une approche de supervision utilisant les réseaux de neurones a été proposée, pour donner une réponse sollicitée à partir de la variable d'entrée (défauts de vibration) pour caractériser les variables de sortie, représentant l'état de fonctionnement de ce système. Cette technique présente une analyse très fine des défauts de vibration et permet de diagnostiquer des défauts de natures différentes dans plusieurs configurations en mode de fonctionnement en temps réel

CHAPITRE IV

SURVEILLANCE DES DEFAILLANCES VIBRATOIRE D'UNE TURBINE EN UTILISANT LES RESEAUX DE NEURONES ARTIFICIELS

Le comportement dynamique des turbines à gaz installés dans les unités de transport du gaz dépend des règles et des plans de surveillances très sophistiqués. Le but de ce chapitre est de mettre en pratique une approche de surveillance des défaillances d'une turbine en utilisant les réseaux de neurones artificiels, dans le but de contribuer à l'élaboration de synthèse de ce système dans le diagnostic des défauts des turbines à gaz. Le système de surveillance des défaillances développé dans ce travail est basé sur une approche prédictive pour le contrôle de la vitesse de la turbine à haute pression. Cela, nous permettra de faire une modélisation fiable de la dynamique de la turbine à gaz GE MS 3002 examinée, pour l'identification et l'isolation des défaillances causées par de vibrations de cette turbine à gaz.

IV.1. Introduction

Les machines tournantes sont soumises à une difficulté très grave à savoir le phénomène de vibration, qui se manifeste par l'instabilité de fonctionnement de la machine, entraînant des dégradations et la rupture des leurs composantes mécaniques. Donc, il est essentiel de surveiller l'exploitation de turbine à gaz en dehors de la zone de vibration. Pour prévenir ce manifestation vibratoire, les turbines à gaz sont dotées de systèmes de surveillance pour contrôler en permanence le mode de fonctionnement de ces machines. Nous étudierons dans ce chapitre l'apport des techniques basées sur les réseaux de neurones artificiels à ces différents systèmes de supervision, on propose d'élaborer un classificateur neuronal – le plus performant que possible – qui génère des indicateurs des défauts permettant de détecter, localiser et caractériser les défauts de vibration en degré de sévérités et en amplitude.

Une stratégie de supervision basée sur les réseaux de neurones artificiels est proposé dans ce travail, pour l'élaboration d'une stratégie de diagnostic pour la détection des dysfonctionnements affichants une turbine à gaz de type GE MS 3002, basée sur une modélisation autorégressive non linéaire dynamique avec entrée exogène externe (NARX). Dans le but de surveiller cette turbine à gaz, un choix préalable d'un certain nombre d'indicateurs issus de mesures et établis en permanence au cours du fonctionnement à été fait.

Vu la complexité des phénomènes vibratoires mis en jeu, le diagnostic de ces phénomènes nécessitent des modélisations de plus en plus fines de leur comportement. Pour cela, la dynamique de la turbine à gaz examinée est étudiée et modélisée utilisant une approche autorégressive non linéaire dynamique avec entrée exogène externe (NARX), servent à une base de données efficace aux modèles aboutissant à l'amélioration de la sécurité et des performances de ce système. Pour prévenir les défaillances et assurer une disponibilité maximale de cette machine tournante.

IV.2. Turbine à gaz

La turbine à gaz examinée dans ce travail est une turbine de modèle MS 3002 à double arbre et cycle simple, elle se compose d'un compresseur axial de 15 étages avec 6 chambres de combustion disposées (90 °) en fonction de direction axiale de la turbine haute pression (HP) comporte un seul étage qui le premier étage, dans le deuxième étage il y a la turbine à basse pression, qui entraîne la charge. Ces caractéristiques techniques sont données dans le Tableau 1.

Cette turbine est installée à la station de compression du gaz à Hassi Massoud au sud de l'Algérie, qui produise plus de 24 millions de mètres cubes/jour de gaz, utilisée dans un réseau de dessertes

principales dont une boucle de gas-lift d'une longueur de 180 kilomètres et de lignes de gaz de réinjection de 28 kilomètres et transportée au ligne des gazoduc pour d'autres applications énergétique en Algérie.

En effet, une turbine à gaz est un équipement qui change l'énergie calorifique en énergie mécanique, ces transformations s'effectuent grâce aux éléments de base du fonctionnement de la turbine à gaz quel que soit sa conception [1-2, 6-7, 19, 21, 30]. Dans sa configuration la plus répandue en industrie de transport du gaz, qui est le cas de cette étude, comme il est présenté sur les Figures IV.1 et IV.2, composée de trois éléments principaux; Compresseur axial, chambre de combustion et la turbine de puissance.

Cependant, cette machine se définit généralement par son type, à un ou à deux arbres et par le modèle de la turbine à entraîner fixe ou mobile et aussi par la nature de son cycle thermodynamique, simple ou avec récupération.



Figure IV.1 : Turbine à gaz TMS3002

Constructeur : General Electric	Puissance Turbine à 80: 9400 CV
Modèle : MS 3002	Débit de consommation combustible (100% HP on 27C)
Serial No: 244370	Température max à l'échappement: 516.6 C
Vitesse HP et compresseur axial: 7100rpm	Pression des gaz d'échappement: 1,009. 3 bar
Nbre étage compresseur axial: 15	Système de démarrage: turbo stator
Nbre étage Roue(s) HP (s): 01	Sens de rotation: anticlockwise
Vitesse BP: 6500 rpm	Nombre d'arbre: 02 Twin Shaft

Tableau IV.1. Caractéristiques techniques de la turbine à gaz MS 3002

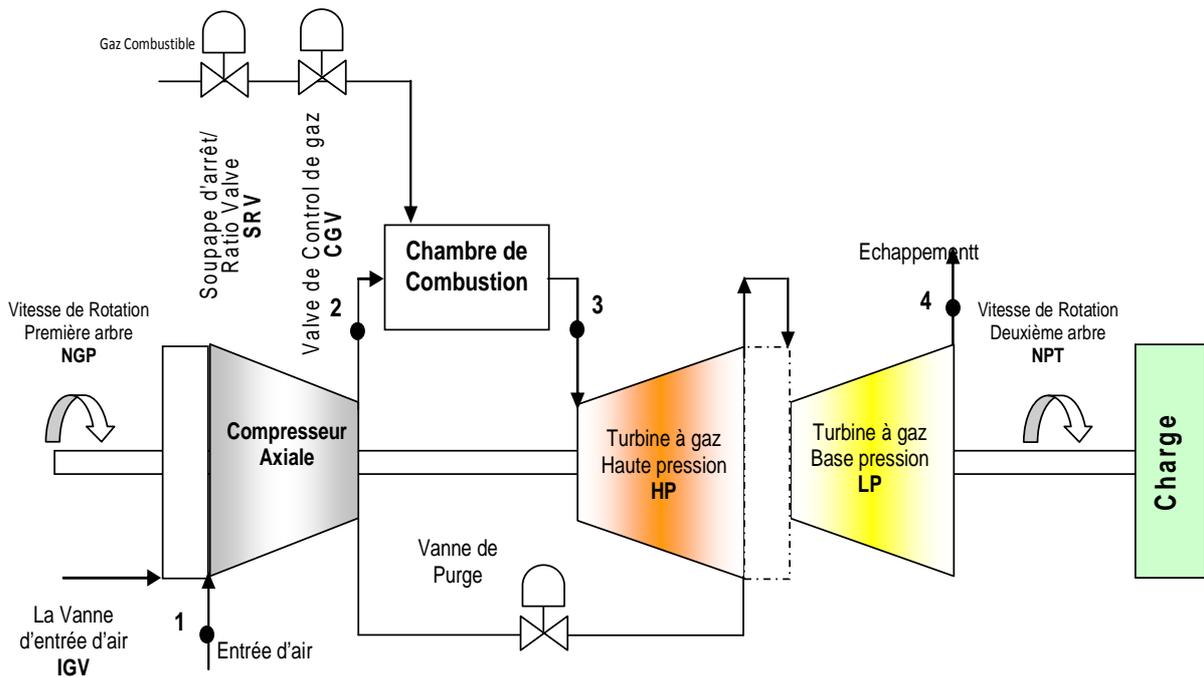


Figure V.2. Turbine à gaz à deux arbres

En réalité industrielle, les problèmes majeurs de l'instabilité rencontrés dans les turbocompresseurs sont l'usure de ces ailettes (surtout les ailettes fixe et les ailettes mobiles), ces ailettes (aubes) sont les éléments les plus chers dans le compresseur, comme il est montré sur la Figure IV.3, une usure causée par [17, 27]:

- Le phénomène d'érosion provoquée par une mauvaise filtration de l'air,
- L'élévation de la température à des grands seuils (1200°C),

Ainsi que le phénomène de vibration est pratiquement provoqué par :

- Un mauvais alignement d'un arbre par rapport à l'autre (arbre compresseur et arbre turbine),
- Un mauvais équilibrage des ailettes (mauvais montage des ailettes) ou du rotor,
- Démarrage de la machine à froid (basse de température de l'huile de graissage),
- Démarrage sans virage,
- Fermeture de la soupape anti-pompage au démarrage de la turbine de lancement.



Figure VI.3. Usure des ailettes du compresseur axial

Le rapport de compression optimale requis dans le compresseur axial est assuré par les 15 étages de ce compresseur, pour améliorer le rendement et la stabilité de la turbine ce rapport est augmenté par étage. Pour cela, il faut augmenter la vitesse de rotor à la limite de stabilité de la machine. Cependant, la turbine à gaz à deux arbres examinée dans ce travail possède l'intérêt à ce que le premier rotor (rotor du compresseur), ait une faible inertie massique pour réduire le temps d'accélération et de décélération de ce rotor. Par contre, le deuxième rotor de la turbine libre, possède une haute inertie massique. Cela donne à ce rotor la fonction d'un volant. Il jouera le rôle de magasin d'énergie qui stabilise la vitesse de rotation et qui évite à un emballement probable en cas de chute de charge.

IV.3. Modélisation de dynamique turbine à gaz GE MS 3002

Pour améliorer la stabilité, la réponse et l'efficacité thermique de l'installation de la turbine à gaz étudiée et fournit un contrôle plus précis de leur exploitation avec un meilleur rendement, la dynamique de la turbine à gaz examinée est modélisée utilisant une approche autorégressive non linéaire dynamique avec entrée exogène externe (NARX), servent à une base de données efficace aux modèles aboutissant à l'amélioration de la sécurité et des performances de ce système et ainsi prévenir les défaillances et assurer une disponibilité maximale de cette machine tournante.

Pour cela, cette turbine est modélisée on servent ces caractéristiques, d'abord la section du compresseur est modélisée en utilisant la pression et la température ambiantes d'entrée (P_a et T_a) de la vanne d'entrée d'air *IGV* (Inlet Guide Vane).

Pour l'obtention du modèle de la vanne d'entrée d'air *IGV* (Inlet guid vane), le modèle de la vanne de purge B_v (Bleed vanne) est utilisé avec la pression et la température ambiantes d'entrée et le retard sur la réponse du *IGV*, où la température ambiante T_a est considérée égale à $T_1 = T_a = 293.15K$ et la pression d'admission du compresseur P_1 est donnée par :

$$P_1 = P_a - \Delta P_a \quad (IV.1)$$

Avec P_a est la pression atmosphérique de la zone d'installation du turbine et ΔP_a est la chute de pression à l'aspiration de système de turbine.

Le modèle de la vanne d'entrée d'air *IGV* (Inlet guid vane) est présenté par l'équation suivante:

$$IGV \% (n) = [P_a (n), T_a (n), B_v (n), IGV \% (n - 1)] \quad (IV.2)$$

Le modèle du valve de control de gaz combustible *CGV* (Gas Valve Control) est obtenu en utilisant la température et la pression au sortie du compresseur T_2 et P_2 avec le débit du gaz combustible F_g (Fuel Gas Flow) et le retard de la réponse de *CGV* estimé, comme suit :

$$P_2 = P_1 \tau \quad (IV.3)$$

Avec τ est le taux de compression.

Pour cela, la température de la sortie du compresseur est donnée par:

$$T_2 = T_1 \left(\frac{P_2}{P_1} \right)^{\frac{(\gamma-1)}{\gamma}} \quad (IV.4)$$

Avec l'exposant isentropique γ est définit par :

$$\gamma = \frac{C_{p(T_1-T_2)}}{C_{p(T_1-T_2)} - r} \quad (VI.5)$$

Où $C_{p(T_1-T_2)}$ définit la chaleur spécifique d'air.

Les valeurs de débit du gaz combustible F_g (Fuel Gas Flow), et valeurs de la vanne de purge B_v (Bleed vanne) sont les valeurs réelles prélevées sur la turbine à gaz examinée dans ce chapitre. Cependant, la valve de control de gaz combustible CGV de la turbine à gaz examinée sera modélisée en se basant sur l'approche autorégressive non linéaire dynamique avec entrée exogène externe (NARX), utilisant la représentation suivante:

$$CGV \%(n) = [IGV \%(n), P_2(n), T_2(n), F_g(n), CGV \%(n-1)] \quad (IV.6)$$

Cela, permet de modéliser la dynamique de la turbine de puissance HP (High Pressure Shaft Speed), utilisant le modèle de la vanne de purge B_v (Bleed vanne), avec la vanne d'entrée d'air dans le compresseur IGV , le débit du gaz combustible F_g , et la valve de control de gaz combustible CGV ainsi que le retard du réponse HP , donnée sous la forme suivante:

$$HP \%(n) = [IGV \%(n), CGV \%(n), F_g(n), B_v(n), HP \%(n-1)] \quad (IV.7)$$

Pour modéliser la dynamique de la turbine à gaz examinée les modèles de l'équation (IV.2), (IV.6) et (IV.7) sont utilisés dans le modèle neuronale de l'approche autorégressive non linéaire dynamique avec entrée exogène externe (NARX) proposée, qui permet de surveiller cette turbine à gaz et prévenir les défaillances de cette machine et assurer une disponibilité maximale avec un meilleur rendement.

IV.4. Surveillance de défaillance d'une turbine à gaz de type GE MS 3002

Récemment, des développements ont été déployés dans l'utilisation des méthodes modernes de diagnostic, pour la surveillance des systèmes industriels [4, 11, 13, 23 et 25]. Ces, méthodes sont basées sur l'insertion des techniques d'intelligences artificielles à des divers applications industrielles. Parmi ces approches, les réseaux de neurones artificiels sont employés vu leurs capacités de modélisation et de calculs.

Le fonctionnement d'un neurone artificiel est montré sur la Figure IV.4. Les variables d'entrées sont $x_1, x_2, x_i \dots x_n$, la somme est pondérée des signaux de ces entrées reçues (en tenant compte du biais). Ils seront modélisés par une fonction de transfert (d'activation).

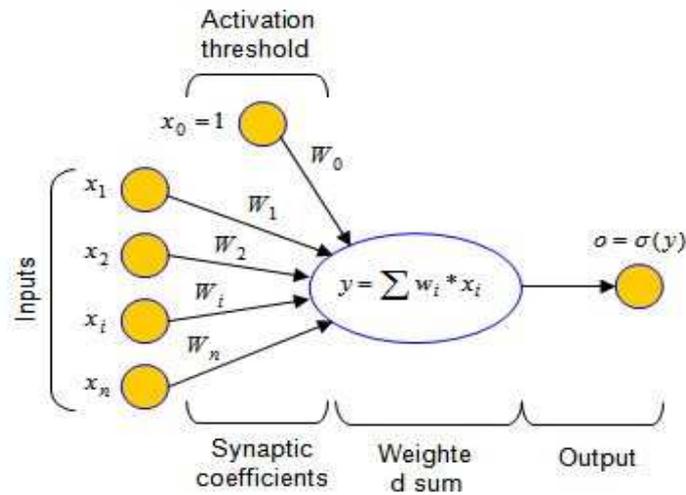


Figure IV.4. Fonctionnement d'un neurone artificiel

L'algorithme d'activation de réseaux de neurones artificiels proposé pour modéliser la dynamique de la turbine à gaz dans ce travail est l'algorithme de gradient descente, donné comme suit :

- Initialiser aléatoirement les coefficients w_i
- Répéter :
 - Pour tout i :
 - $\Delta w_i = 0$
 - Fin Pour
 - Pour toute entrée (x, c) dans S
 - Détermination de la sortie de réseau
 - Pour tout i :
 - $\Delta w_i = \Delta w_i + \varepsilon * (c - o) * x_i * \sigma'(x.w)$
 - Fin Pour
 - Fin Pour
 - Pour tout i :
 - $w_i = w_i + \Delta w_i$
 - Fin Pour
- Fin Répéter

La méthode de gradient est donnée par la formulation suivante:

$$\begin{aligned}
 x_{n+1} &= x_n - \varepsilon * f'(x_n) = x_n + \Delta x_n \\
 \frac{\partial E(W)}{\partial w_i} &= \frac{1}{2} \frac{\partial}{\partial w_i} \sum (c-o)^2 = \frac{1}{2} \sum_s \frac{\partial}{\partial w_i} (c-o)^2 \\
 &= \frac{1}{2} \sum_s 2(c-o) \frac{\partial}{\partial w_i} (c-o) = (c-o) \frac{\partial}{\partial w_i} (c-\sigma(x.w))
 \end{aligned} \tag{IV.8}$$

Avec:

$$\begin{aligned}
 \frac{\partial}{\partial w_i} (c-\sigma(x.w)) &= \frac{\partial}{\partial w_i} (c-\sigma(y)) = \frac{\partial}{\partial y} (c-\sigma(y)) * \frac{\partial y}{\partial w_i} = -\sigma'(y) * x_i \\
 \frac{\partial E(W)}{\partial w_i} &= \sum_s (c-o)(-x_i) \sigma'(x.w)
 \end{aligned} \tag{IV.9}$$

D'où:

$$\Delta w_i = -\varepsilon * \frac{\partial E(W)}{\partial w_i} = \varepsilon \sum_s x_i * (c-o) * \sigma'(x.w) \tag{IV.10}$$

Pour établir le lien symptômes - situations types de la turbine à gaz examinée dans ce travail, il convient à prédire des liens entre un ensemble de paramètres prélevées pendant leur fonctionnement pendant l'exploitation de système avec des situations de références connues a priori. Utilisant l'approche de réseaux de neurones dynamique, peut s'interpréter comme il est indiqué par la Figure IV.5 .

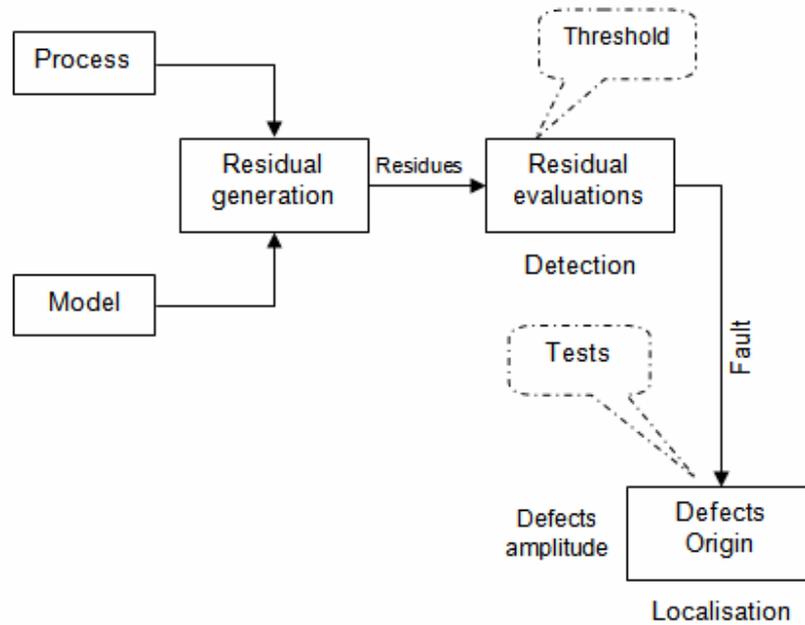


Figure IV.5: Analyse d'indicateurs de défauts

La robustesse de l'approche proposée dans ce travail a permis d'augmenter la capacité à détecter des défauts dans le processus examiné avec des erreurs pratiquement acceptables de système de turbine à gaz. Récemment, avec la multiplication des sources d'information et la croissance des outils de calculs de l'informatique industrielle, l'utilisation et l'évaluation de modèles basés sur les réseaux de neurones artificiels en milieu industriel deviennent des tâches faciles. Où ces techniques de l'intelligence artificielle se présentent aujourd'hui comme une solution, permettant de souligner les problèmes de complexités (non linéarités) de ces systèmes industriels. En effet, la fonction de diagnostic des dysfonctionnements de la turbine examinée est réalisée en utilisant un système autorégressif non linéaire dynamique avec entrée exogène externe (NARX) basé sur une structure de réseaux de neurones dynamiques, ce système est représenté mathématiquement par :

$$\begin{aligned}
 y(n+1) &= f \left[\begin{array}{l} y(n), \dots, y(n-d_y+1) \\ u(n), u(n-1), \dots, u(n-d_u+1) \end{array} \right] \\
 &= f[y(n); u(n)]
 \end{aligned} \tag{VI.11}$$

Avec $u(n)$ représente les entrées, $y(n)$ représente les sorties et n est une unité de temps, $d_u \geq 1$ et $d_y \geq 1$, $d_u \leq d_y$ sont les ordres de mémoire d'entrée et de mémoire de sortie de réseaux de neurones et $f(\cdot)$ c'est sa fonction d'activation.

La structure de réseaux de neurones dynamique utilisée dans ce travail est une architecture multicouche avec la partie d'entrée et des parties masquées et une partie de sortie, avec une fonction d'activation de type sigmoïde, montré sur la Figure IV.6, donnée par:

$$f_1 = \frac{2}{1 + e^{-2\alpha}} - 1 \quad (\text{VI.12})$$

La fonction d'activation de type linéaire, montrée sur la Figure IV.7, pour la couche de sortie donnée par :

$$f_2 = x \quad (\text{VI.13})$$

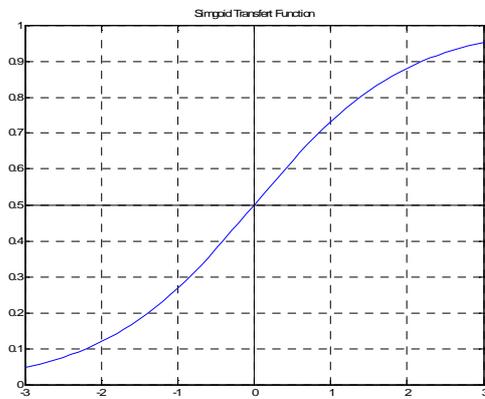


Figure IV.6. Fonction d'activation de type sigmoïde

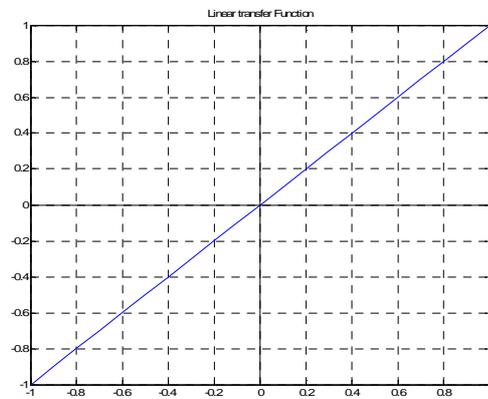


Figure IV.7. Fonction d'activation de type linéaire

La fonction de rétro propagation est employée pour l'étape d'apprentissage et les règles d'apprentissage sont utilisées pour optimiser l'erreur quadratique, donnée comme suite :

$$E = \frac{1}{2} \sum_i (d_i - y_i)^2 = \frac{1}{2} \sum_i \left(d_i \sum w_{ij} x_j \right)^2 \quad (\text{IV.14})$$

Où le changement du poids w_{ij} par une quantité Δw_{ij} doit être proportionnel au gradient d'erreur donnée par:

$$\Delta w_{ij} = -\eta \frac{dE}{dw_{ij}} = \eta \sum_i (d_i - y_i) x_i \quad (\text{IV.15})$$

La somme pondérée des entrées de réseaux de neurone dynamique seront calculées à l'aide de l'expression suivante:

$$a_j = \sum_{j=1,n} w_{ij} x_j \quad (IV.16)$$

A partir de cette équation on peut calculer les valeurs de la fonction d'activation et obtenir l'état de neurone, leurs valeurs seront utilisées dans les neurones en aval de système, données par l'équation suivante:

$$y_i = \varphi(a_i - \theta_i) \quad (IV.17)$$

L'organigramme de gradient est employé pour calculer les dérivées des entités de système de turbine par rapport à toutes ses entrées, pour calculer ces sorties, on a :

$$\begin{aligned} u_j &= f_1\left(\sum_{i=1} w_{ij}^1 x_i + w_{ki}^1 x_k + b_j^1\right) \\ y_k &= f_2\left(\sum_{i=2}^N u_i + b_k^2\right) \end{aligned} \quad (VI.18)$$

Où : $f_1(v) = \frac{2}{1 + e^{-2v}} - 1$, $f_2(v) = v$ sont respectivement les fonctions sigmoïde d'activation, k est l'indice du couche de sortie, i l'indice de couche d'entrée, j est l'indice du couche caché, w_{kj} est le poids synaptique, w_{ji} est le poids synaptique entre les couches d'entrées et cachées, w_{ki} le poids synaptique entre les couches de sortie et d'entrées, x_i est la connexion entre les couches d'entrées et cachées et b_j^1 est le biais du neurone j .

Le modèle établi par le système autorégressive non linéaire dynamique avec entrée exogène externe (NARX), montré sur la Figure IV.8, avec un feedback de sortie vers l'entrée pour minimiser la fonction du coût, peut prédire la valeur future des sorties $y(t)$ avec la valeur précédente du $y(t)$ et la valeur précédente du $x(t)$. Une fois le réseau est bouclé, il est nécessaire de fournir des estimations futures sur un horizon de prédiction N , où les prédictions sont exécutées de manière récursive jusqu'à ce que l'horizon de prévision souhaité soit atteint, ces réseaux sont évalués en termes d'erreur quadratique moyenne normalisée (NMSE), donnée par:

$$NMSE (N) = \frac{1}{N \cdot \sigma_x^2} \sum_{n=1}^N (x(t+1) - \hat{x}(t+1))^2 \quad (IV.19)$$

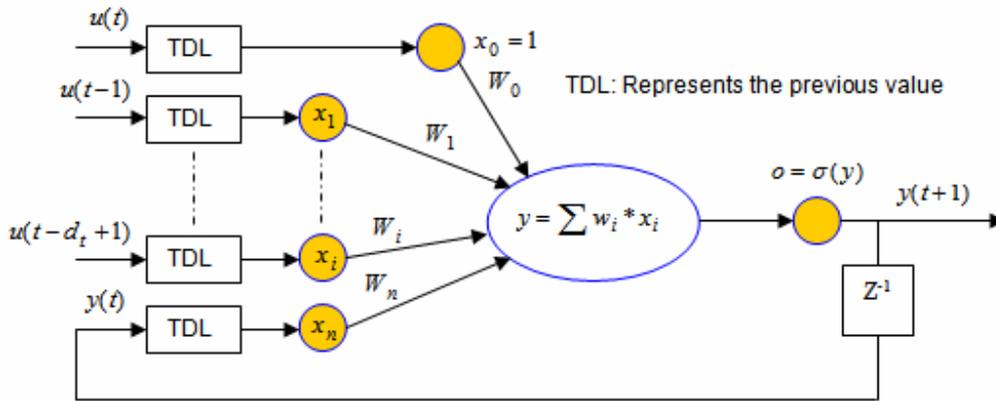


Figure IV.8. Autorégressive non linéaire dynamique avec entrée exogène externe (NARX)

L'algorithme utilisé pour minimiser la fonction E est basé sur la méthode du gradient, cette algorithme commence par un choix incertain des vecteurs premiers du poids w_i , utilisant l'algorithme du rétro-propagation, l'erreur adapte les poids synaptique w de façon à minimiser la fonction du coût E , les étapes de cet algorithme sont données comme suit:

- Début

$$E(W) = \sum_{p=1}^T E_p(W)$$

$$E_p(W) = \frac{1}{2} \sum_{i=1}^m [y_i^d(k) - y_i(k)]^2$$

- Adaptation des poids :

$$E(W) = \sum_{p=1}^T E_p(W)$$

$$\Delta W_{ij}^l = lr \cdot \frac{dE(W)}{dW_{ij}^l(k)}$$

k nombre d'itération

lr pas d'apprentissage

Fin Pour

- Dérivée de la fonction coût E :

$$\frac{dE(W)}{dW_{ij}^l} = \sum_{p=1}^T \frac{dE_p(W)}{dW_{ij}^l(k)}$$

- Et pour la couche cachée:

$$\frac{dE_p(k)}{dW_{ij}^l} = \sum_{p=1}^{N_{i+1}} \frac{dE_p(W)}{dE_q^{l+1}(k)} \cdot \frac{dE_q^{l+1}(k)}{dE_i^l(k)}$$

$$\frac{dE_p(k)}{dW_{ij}^l} = f'(P_i^l(k)) U_j^{l-1}(k)$$

$$\frac{dE_p(W)}{dW_{ij}^l} = \frac{dE_p(W)}{dU_j^l(k)} \cdot f'(P_i^l(k)) U_j^{l-1}(k)$$

- Et pour la couche de sortie

$$\frac{dE_p(k)}{dU_j^l(k)} = (y_i^d(k) - y_i(k))$$

- Fin

Le modèle d'une turbine en utilisant les techniques autorégressive non linéaire dynamique avec entrée exogène externe (NARX), est exploré et expérimenté, sur des données issues à partir de la turbine à gaz examinée. Cette approche est investiguée et permettant la proposition des nouvelles procédures de surveillance de la turbine à gaz avec la mise au service du diagnostic de défauts des machines tournantes, utilisant les donnée d'exploitation et l'information recueillie lors de son fonctionnement. Cela, a permet en plus de fournir des outils de diagnostic efficaces pour ce type de machines.

IV.5. Résultats d'application de procédure de surveillance de turbine GE MS 3002

Dans cette section, des procédures de surveillance d'une turbine à gaz de type GE MS 3002, basées sur les réseaux ont été réalisés pour la supervision de cette machine. Le but est d'identifier et d'isoler les dysfonctionnements dans ce système de turbine, en appliquant la méthode de diagnostic à base de la modélisation autorégressive non linéaire dynamique avec entrée exogène externe (NARX). Des résultats expérimentaux seront illustrés pour chaque composant de la turbine à gaz grâce aux tests effectués en temps réel sur le système de compression du gaz de la turbine GE MS 3002 en utilisant le système de diagnostic proposé.

Nous étudierons premièrement la structure de modèles obtenue. Puis, nous donnerons les résultats des tests effectués sur cette application, conformément au cahier des charges.

Les composantes assurant le fonctionnement de la turbine à gaz examinée ont été modélisées en utilisant le système NARX proposé. Dans ce système de turbine à gaz le compresseur axial est entraîné par la vitesse d'arbre de la turbine à haute pression HP.

Cela est contrôlé par l'entrée d'air IGV commandée par sa vanne motorisée pour régler la quantité d'air à l'entrée axial. D'ù, la vanne de commande du gaz CGV ajuste sur le gaz combustible à l'entrée de la chambre de combustion. Cependant, la soupape de purge à l'entrée de l'arbre de turbine à basse pression BP ajuste sur le débit de gaz combustible après la chambre de combustion. La Figure IV.9, montre la variation de vitesse de rotation de turbine à haute pression avec deux points critiques en 7000 s et en 11000 s.

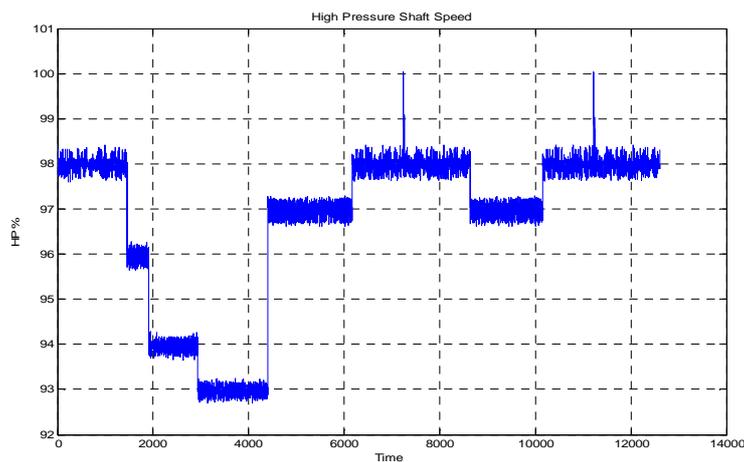


Figure IV.9. Variation de rotation de la turbine à haute pression HP

La Figure IV.10, montre la variation du modèle neuronale NARX de la vanne de commande d'aire IGV, cette vanne s'ouvre et se ferme en pourcentage %, le réseaux de neurones dynamique utilise la fonction objective E, donnée à la section précédente, qui minimise l'erreur sur le modèle, la courbe en rouge est le pourcentage d'ouverture de la vanne IGV et la courbe en bleu c'est la sortie de modèle NARX avec la réponse d'erreur en bas. La Figure IV.11, montre les performances obtenues pour le modèle NARX de la vanne de commande d'aire, ces performances sont présentées en fonction d'erreur entre le signal et la sortie de réseaux par un critère d'erreur quadratique moyenne qui est à l'ordre 10^{-3} .

La Figure IV.12, présente la variation de modèle de la vanne de contrôle de gaz CGV avec son modèle NARX et la Figure IV.13 montre ces performances de validation obtenues par le modèle NARX.

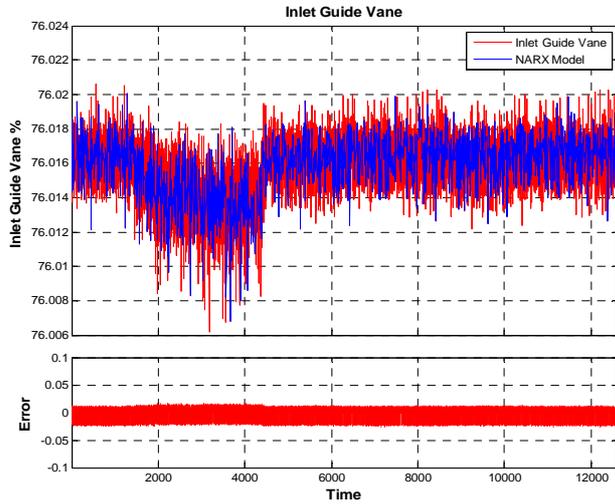


Figure IV.10: Variation du modèle de la vanne de commande d'air IGV avec son modèle NARX

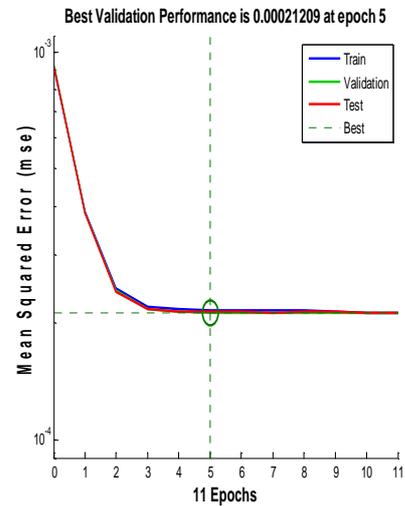


Figure IV.11: Performances du modèle NARX de la vanne de commande d'air IGV

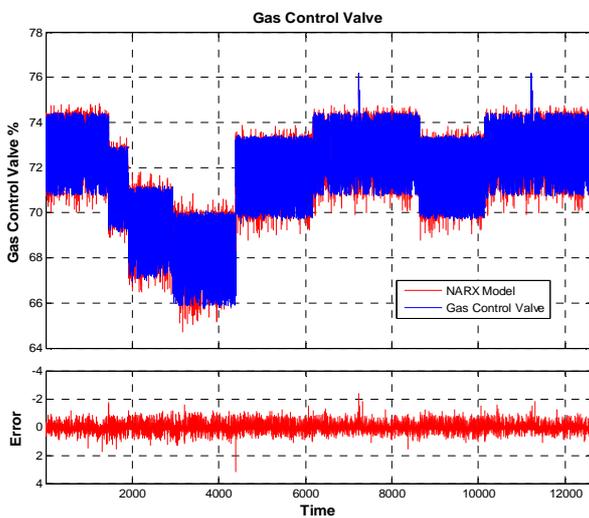


Figure IV.12: Variation du modèle de la vanne de contrôle de gaz CGV avec son modèle NARX

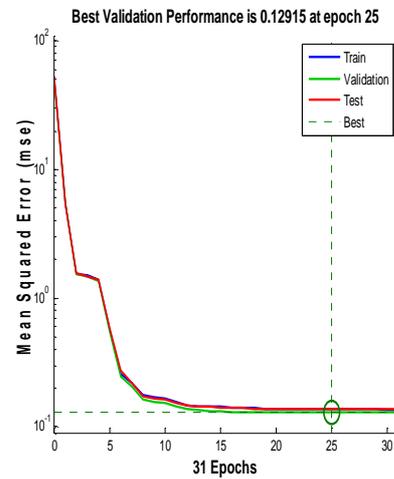


Figure IV.13: Performances du modèle NARX de la vanne de contrôle de gaz CGV

La Figure IV.14, présente la variation de modèle de l'arbre de la turbine à haute pression HP avec son modèle NARX et la Figure IV.15 montre ces performances de validation obtenues par le modèle NARX.

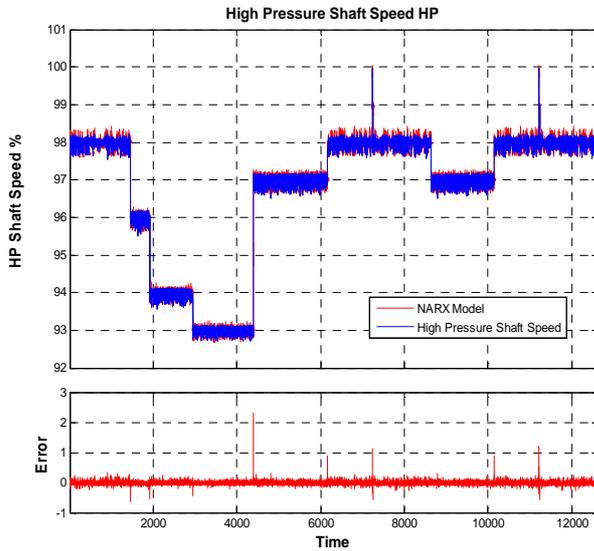


Figure IV.14: Variation du modèle de l'arbre de la turbine à haute pression HP avec son modèle NARX

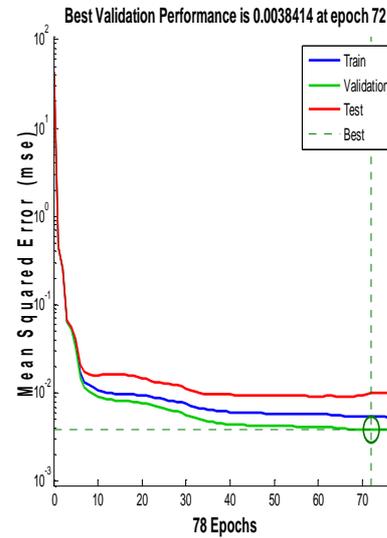


Figure IV.15: Performances du modèle NARX de l'arbre de la turbine à haute pression HP

Les Tableaux IV.2, IV.3 et IV.4, présentent la répartition des données réelles en trois catégories, 70% des données pour l'entraînement du réseau, 15% pour la validation, et le 15% qui reste pour le test de la performance de réseau de neurones avec le résultat de la fonction de coût MSE de résultats de modélisation. Les résultats tirés dans ce travail montrent que les réseaux de neurones explorés par l'estimation des variables de la turbine examinée ont été parfaitement modélisés en utilisant le système NARX proposé, une chose qui nous permet de présenter son comportement dynamique assurant son fonctionnement optimal.

Réseau de Neurones	Partition du donnés	Erreur Quadratique Moyenne	Régression R
Apprentissage	8828	2.16103e-4	4.41184 e-2
Test	1892	2.12090 e-4	4.51141 e-2
Validation	1892	2.13941 e-4	4.73218 e-2

Tableau VI.2. Performances du Modèle NARX de la vanne de commande d'air IGV

Réseau de Neurones	Partition du donnés	Erreur Quadratique Moyenne	Regression R
Apprentissage	8828	1.37210e-1	9.80678e-1
Test	1892	1.29152e-1	9.81975e-1
Validation	1892	1.37684 e-1	9.80511e-1

Tableau VI.3. Performance du Modèle NARX de la vanne de contrôle de gaz CGV

Réseau de Neurones	Partition du donnés	Erreur Quadratique Moyenne	Régression R
Apprentissage	8828	5.4034e-3	9.99115e-1
Test	1892	3.8414e-3	9.98882e-1
Validation	1892	9.16117e-3	9.98566e-1

Tableau VI.4. Performances du Modèle NARX de l'arbre de la turbine à haute pression HP

Le Tableau VI.5 ci-dessous illustre l'erreur quadratique moyenne normalisé des modèles qui est le résidu donné par l'écart entre les paramètres réelles et prédites.

Parameters RMSE	la turbine à haute pression HP	la vanne de contrôle de gaz CGV	la vanne de contrôle de gaz CGV
l'erreur quadratique moyenne normalisée	3.8414e-3	1.29152e-1	2.12090 e-4

Table VI.5. Performances du Model NARX

Les résultats obtenus exposent que une modélisation avec l'approche NARX pour la turbine examinée a un effet très important et bénéfique. En effet, avec une plus forte influence des données utilisées selon leurs contenu et qualité ils peuvent apporter des modèles améliorés comme il est montré sur le test de la Figure IV.16 de modèle de l'arbre de turbine à haute pression HP avec son modèle NARX , comme il fournit des outils de surveillances pratiques le plus adaptés pour la modélisation de la turbine à gaz MS 3002 examinée.

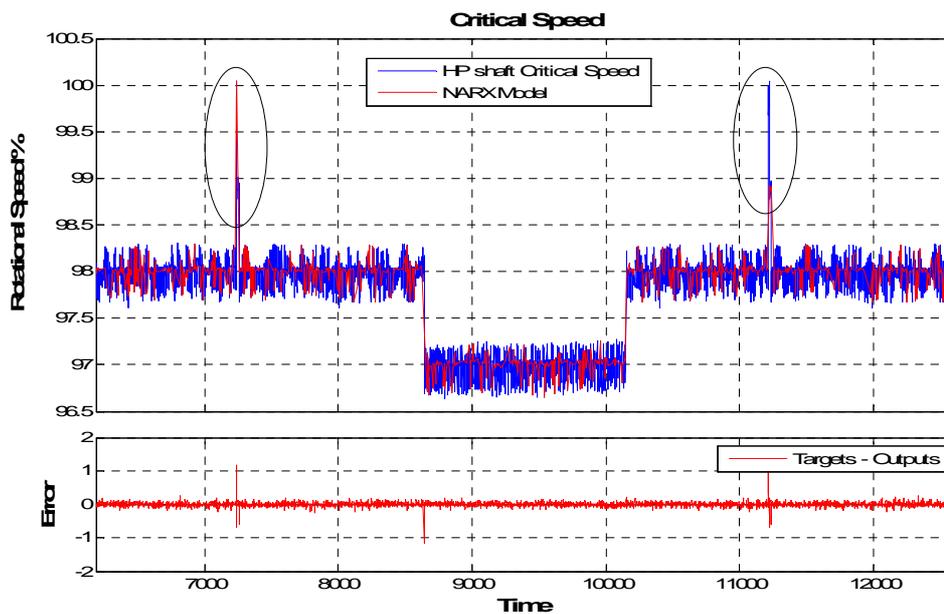


Figure IV.16. Variation du modèle de l'arbre de la turbine à haute pression HP avec son modèle NARX

IV.6. Contrôle de vitesse de la turbine haute pression

Dans cette partie du travail de thèse, le contrôle de la vitesse de la turbine haute pression sera présenté, dans le but de protéger et de surveiller le comportement dynamique de la turbine à gaz examinée. Le contrôleur proposé est combiné avec le système de réseaux de neurones, dans le but d'augmenter la capacité de commande et d'accroître la fiabilité de ce système de régulation proposé à la turbine. En effet, l'arbre à haute pression c'est l'organe le plus affecté par les vibrations, ces phénomènes d'instabilités peuvent diminuer davantage le rendement de la machine et causés des dégradations de fonctionnement.

Le but de l'application du réseau neuronal est le contrôle de la vitesse de rotation d'arbre de turbine à haute pression. Les principaux objectifs est de stocker et de représenter les connaissances acquises, de

donner par la suite une solution au problème à partir de ces connaissances acquises et d'acquérir de nouvelles connaissances pendant le fonctionnement de système de la turbine. Pour y arriver, le réseau multicouches est employé pour la modélisation et le contrôle de la machine tournante examinée, avec une fonction sigmoïde et linéaire respectivement dans les couches (cachée et de sortie) de système définie par l'équation:

$$u_j = f_1\left(\sum_{i=1} w_{ij}^1 x_i + b_j^1\right)$$

$$y_k = f_2\left(\sum_{l=1}^N w_{lk}^2 u_l + b_k^2\right)$$
(IV.20)

Avec f_1, f_2 représente les fonctions d'activation.

L'algorithmme de rétro propagation utilise la règle d'apprentissage pour minimiser l'erreur carrée donnée par l'équation suivante:

$$E_{app}(w) = \frac{1}{2} \sum_{k \in E_{app}} \sum_{j=1}^m |y_j(x_k, w) - d_{jk}|^2$$
(IV.21)

Avec d_{jk} est $j^{ème}$ élément de la sortie désiré, d_k est la sortie du réseau de $k^{ème}$ élément de l'ensemble d'apprentissage.

La turbine à haute pression examinée est de type MS 3002 est un moteur à combustion interne doté d'une double tête et d'un cycle simple, il se compose d'un compresseur axial de 15 étages, 6 chambres de combustion disposée (90 °) en alimentant la turbine à haute pression axiale a une seul étage (première étage) qui entraîne le compresseur et son équipement auxiliaire et une turbine basse pression (deuxième étage) qui entraîne la charge (alternateur ou compresseur). La turbine entière se compose de trois éléments principaux: Compresseur axial, la turbine d'énergie et une chambre de combustion, comme il est montré sur la Figure IV.17.

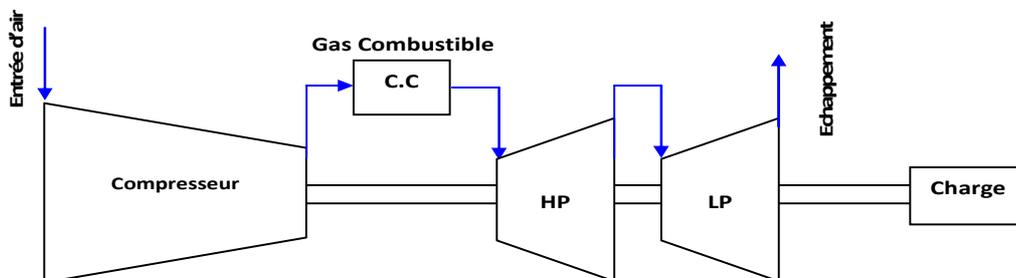


Figure IV.17 : Turbine à gaz MS3002

Le modèle prédictive contrôle basé sur le réseau neuronal proposé est montré sur la Figure IV.18, pour extraire les modèles de cette machine, les données réelles ont été utilisé pour former le réseau neuronal. Dans le but de régler la vitesse de rotation de l'axe génératrice de cette turbine, afin de prévoir leur comportement et pour faciliter la planification du futur action de commande.

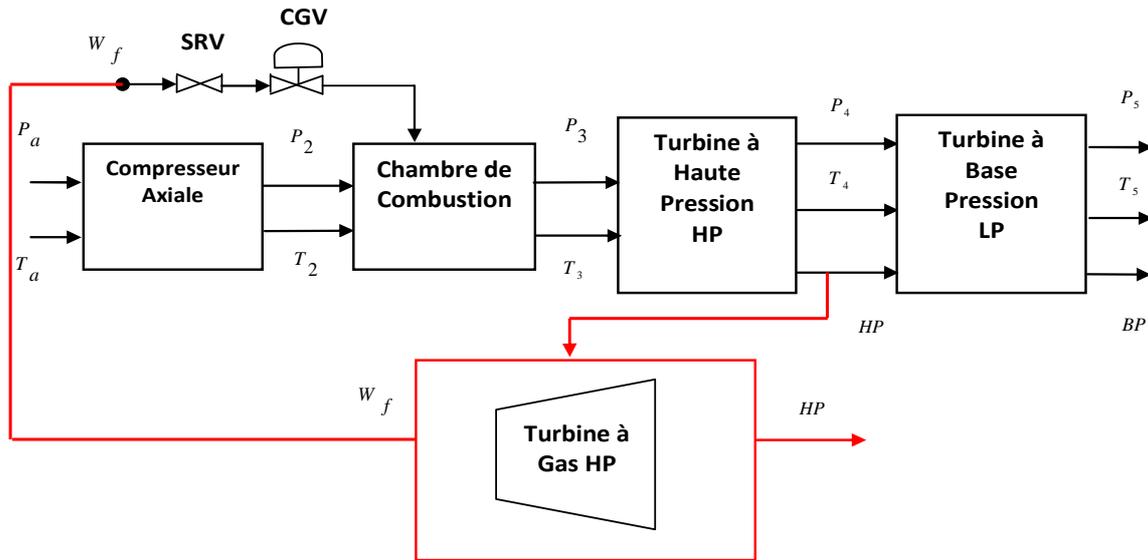


Figure IV.18 : Contrôle de la vitesse de l'arbre de la turbine MS3002 à haute pression

Le débit du carburant W_f est proposé comme entrée du modèle prédictive de contrôle et la vitesse de rotation de l'arbre haute pression HP comme sortie, avec la variation du débit de combustible W_f dépend par la température T_2 et la pression à la sortie du compresseur P_2 . Cela permet d'actionner sur la vanne de control du gaz CGV et la soupape d'arrêt du gaz SRV .

La pression et la température à la sortie du compresseur (P_2 et T_2) sont définis par l'équation suivante:

$$\begin{aligned} P_2 &= P_1 \cdot \tau \\ T_2 &= T_1 \left(\frac{P_2}{P_1} \right)^{\frac{(\gamma-1)}{\gamma}} \end{aligned} \quad (IV.22)$$

d'où τ est le taux de compression du gaz, $\gamma = \frac{C_{p(T_1-T_2)}}{C_{p(T_1-T_2)} - r}$ est l'exposant isentropique du gaz avec $C_{p(T_1-T_2)}$ définit la chaleur spécifique d'air entre T_1 et T_2 .

La variation du rotor HP caractérisée par la température T_3 et la pression P_3 , le débit du combustible W_f et la variation du vanne de control du gaz CGV , sont représentés par l'équation suivante:

$$HP_{speed} = [P_3, T_3, W_f, CGV] \quad (IV.23)$$

Avec la pression P_3 est déterminée par la formule suivante:

$$\begin{aligned} P_3 &= P'_2 - \Delta P_{cc} \\ P_3 &= P'_2 - \Delta P_{cc} \\ P'_2 &= P_1 \cdot \tau \end{aligned} \quad (IV.24)$$

Avec ΔP_{cc} la perte de charge dans la chambre de combustion

La température T_3 est déterminée par la formule suivante:

$$T_3 = T_0 + \frac{Q_{ac} \cdot C_{p(T'_2, T_0)} + \eta_{cc} \cdot Q_c \cdot P_{ci}}{(Q_{ac} + Q_c) \cdot C_{p(T_0, T_3)}} \quad (IV.25)$$

Avec Q_{ac} est le débit d'air combustible, Q_c est le débit de combustible, η_{cc} est le rendement de la chambre de combustion, $C_{p(T'_2, T_0)}$ est la chaleur spécifique d'air pour les températures T'_2 et T_0 et P_{ci} est le pouvoir calorifique inférieur de combustible.

Pour la surveillance de la dynamique vibratoire de la turbine un modèle basé sur les techniques de réseaux de neurone avec contrôle prédictive de la vitesse de l'arbre est utilisé, comme il est montré sur la Figure IV.19, pour prédire la performance optimale de cette machine on utilise une critère de performances donnée par:

$$j = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2 \quad (IV.26)$$

Avec N_1, N_2 et N_u représente les horizons sur lesquels l'erreur de suivi du modèle de référence, u' est le signal de commande de la vitesse de l'arbre, y et y_m sont la réponse désirée et la réponse du modèle de réseau.

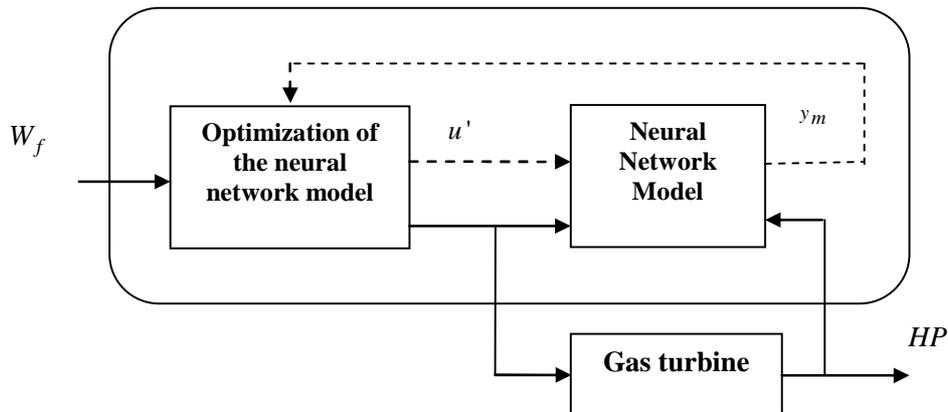


Figure IV.19 : Modèle prédictif du contrôle de la vitesse d'arbre à haute pression basé sur réseau de neurone

Dans la section suivante, les résultats d'application de la méthode de modèle prédictive de contrôle des paramètres d'une turbine à gaz seront présentés. Cette méthode permet d'établir un régulateur avec des contraintes sur le contrôle de la sortie de turbine à gaz examinée.

IV.7. Résultats d'applications de contrôle de la vitesse HP de la turbine

Dans cette partie de travail, les résultats expérimentaux établis seront présentés, les tests expérimentaux de l'approche proposée ont été réalisés en conditions réelles sur la turbine à gaz examinée. Pour collecter et analyser les données de cette machine, des moyens informatiques et logiciels ont été utilisé pour le traitement des signaux émis par les différents types de vibrations engendrées par les différents composants de la turbine à gaz examinée.

L'analyseur du spectre en temps réel utilisant des collecteurs de données sur le processus de la turbine à examinée, permet d'accéder rapidement aux informations et d'échanger des données standardisées de cette turbine à gaz. Les signaux ont étaient enregistrés directement sur un computer dans la salle de contrôle avec une carte de pilotage et d'acquisition, où nous avons utilisé ces données de système d'acquisition. Les signaux temporels et les conditions d'essais sont archivés et attaché à chaque point de mesures réalisés avec le choix des paramètres adéquats à notre approche de modèle prédictive de contrôle des paramètres de la turbine proposée.

En effet, le modèle développé dans ce travail, montré sur la Figure IV.20, traite le comportement dynamique d'un rotor de la turbine à gaz tournant à haute vitesse et supportée par des défauts de balourd et désalignement (vibrations), en tenant compte des effets des contraintes sur le système examiné.

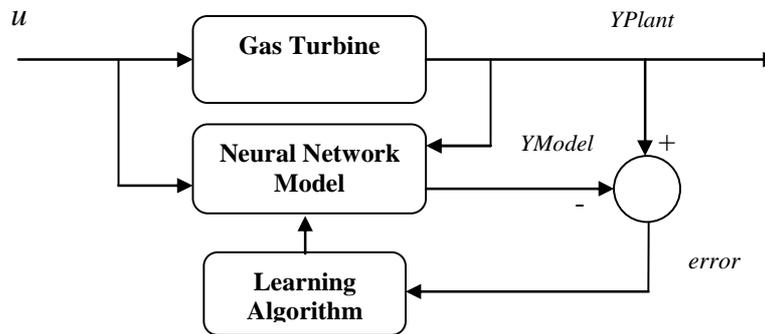


Figure IV.20 : Modèle prédictif du contrôle basé sur le réseau de neurone

Nous montrons que le système étudié présente des zones d'instabilités variant avec la fréquence de rotation et aux réponses des rotors aux balourds. Cela, peut créer de nouvelles fréquences critiques sur la turbine à gaz examinée.

L'identification de modèle pour le contrôle des variables de la turbine est complète, l'optimisation de performances de ce modèle à été testé par l'algorithme d'apprentissage de réseaux de neurone utilisé. Ainsi les paramètres optimale pour l'entrée de débit de carburant est à l'ordre de 23.0799 - 26.6069 et les valeurs minimales et maximales de sortie de la vitesse de l'arbre de générateur de gaz sont obtenues à l'ordre de 93% - 100% après l'apprentissage de réseaux de neurone utilisé, utilisant des données du réseau de 12612 data, comme il est présenté sur la Figure IV.21.

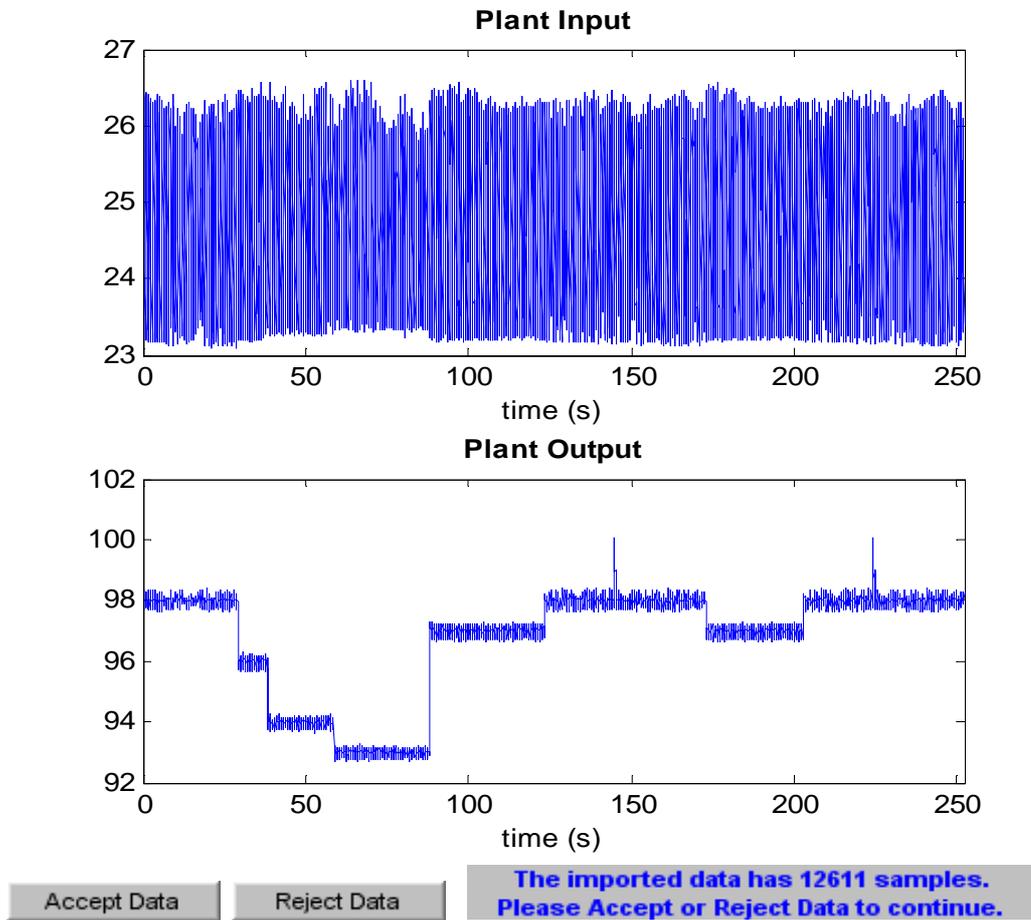


Figure IV.21 : Données d'identification des variables de la turbine à gaz examinée

Des tests effectués sont réparties sur trois parties, selon trois phases de fonctionnement de la turbine, comme il est présenté sur les Figures IV.22, IV.23 et IV.24; la première phase sur 75% pour l'apprentissage, ensuite sur 15% de la deuxième phase et finalement sur 10% de la troisième phase pour la validation du modèle neuronale.

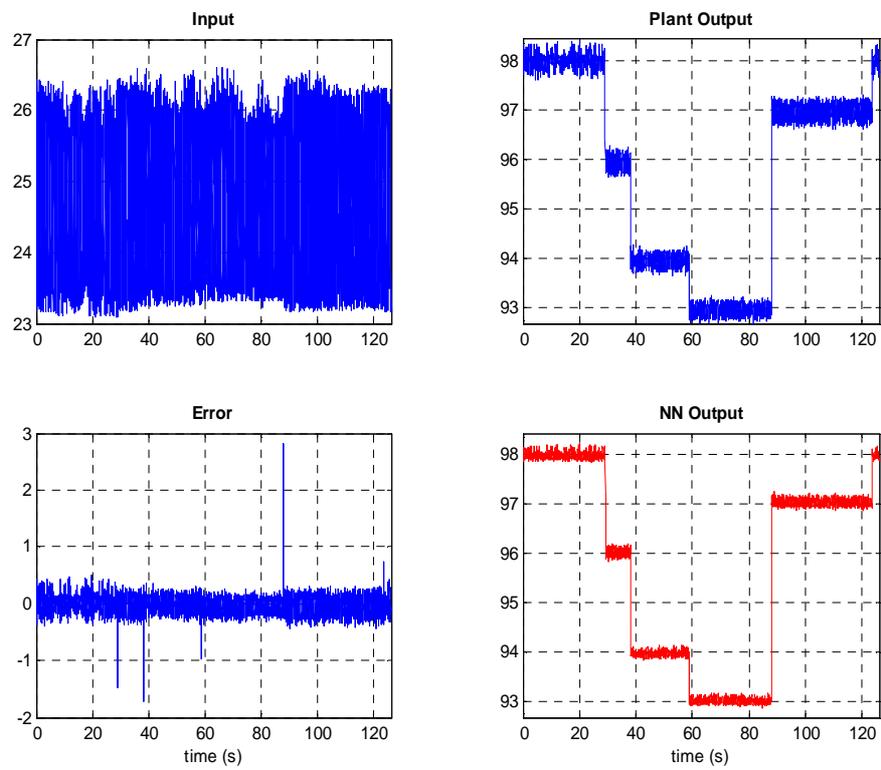


Figure IV.22 : Première phase sur 75% pour l'apprentissage du modèle de réseau de neurone

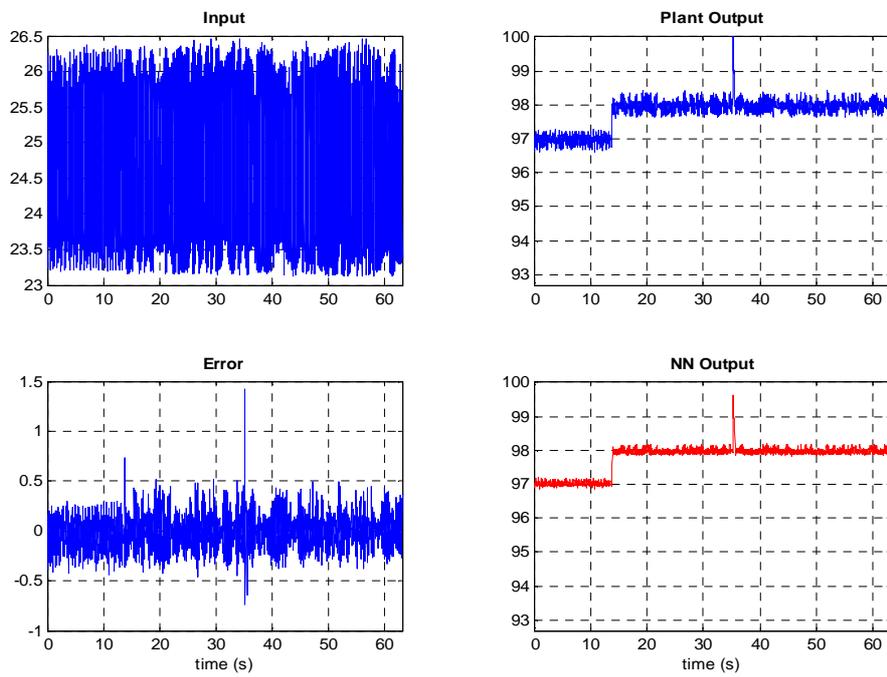


Figure IV.23 : Deuxième phase sur 15% pour test de détection du modèle de réseau de neurone

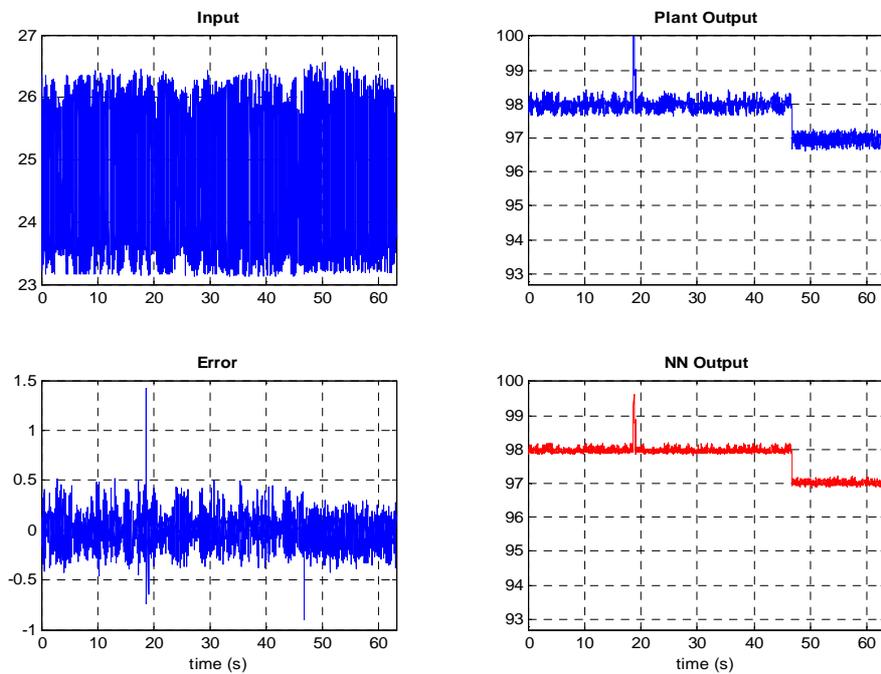


Figure IV.24 : Troisième phase sur 10% pour validation de modèle du réseau de neurone

L'erreur quadratique moyenne MSE est calculée, comme il est montré sur la Figure IV.25, pour mesurer l'amplitude de l'erreur et valider l'approche de modélisation proposée, en utilisant la formule suivante:

$$MSE = \frac{\sum_{i=1}^n (x_i - u_i)^2}{n} \quad (IV.27)$$

Avec x_i est la valeur de sortie désiré, u_i est la sortie prédite du réseau de neurone et n est le nombre du data de sortie.

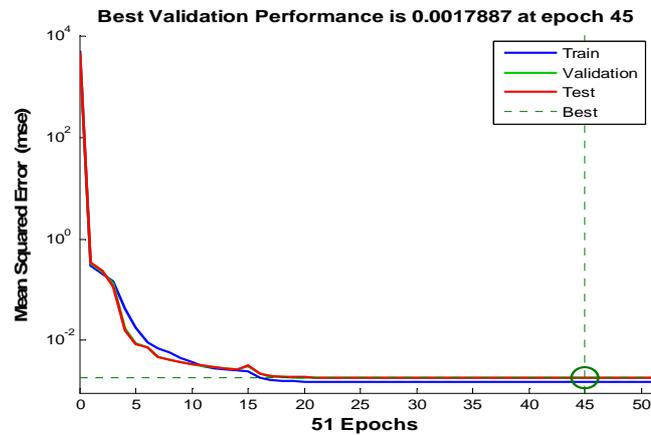


Figure IV.25: Erreur quadratique moyenne MSE

Un autre test pour la robustesse de l'approche proposée est obtenu par la détermination du coefficient statistique, comme il est montré sur la Figure IV.26, pour voir la variation de la variance dans les sorties désirée, ce coefficient statistique est donnée par:

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - u_i)^2}{\sum_{i=1}^n u_i^2} \quad (IV.28)$$

La valeur de MSE est orientée négativement ces valeurs montrent une meilleure performance du réseau. Contrairement à la statistique MSE , R^2 est positivement orientée, la valeur R^2 devrait converger près de 1 pour le meilleur ajustement de modèle.

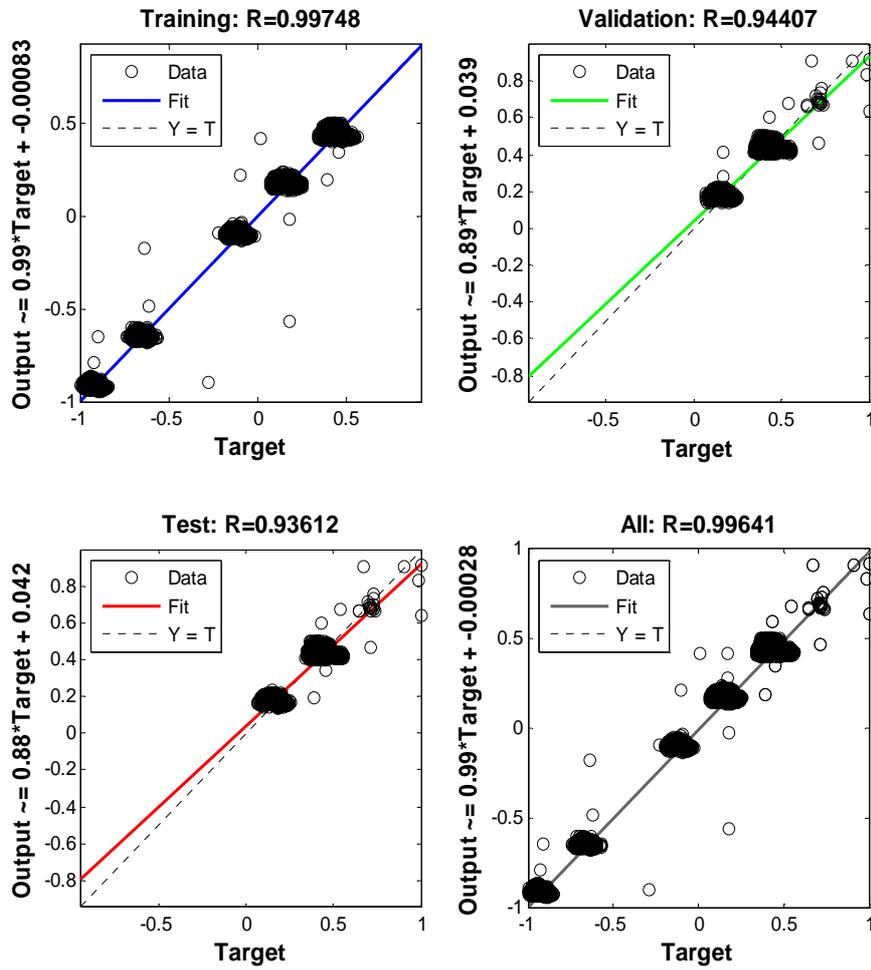


Figure IV.26 : Corrélation du modèle de réseau de neurones

Après l'activation du réseau de neurones, la vitesse de l'arbre haute pression *HP* réelle comparée par le modèle contrôlé de réseaux de neurones est montré sur les Figures IV.27 et IV.28.

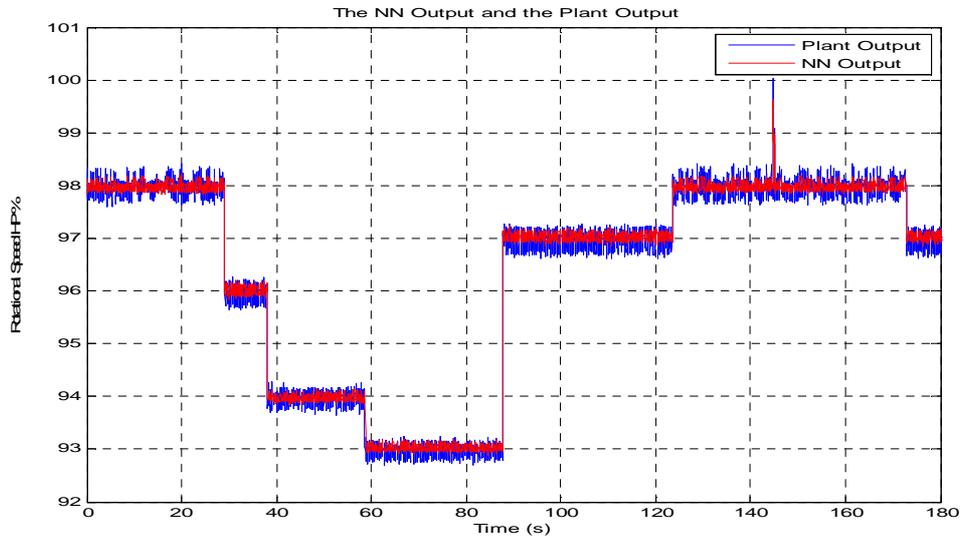


Figure IV.27: Vitesse de rotation de l'arbre HP comparé avec modèle contrôlé de réseaux de neurones

La variation de la vitesse de l'arbre haute pression *HP* réelle avec le modèle contrôlé de réseaux de neurones est présentée ci-dessous.

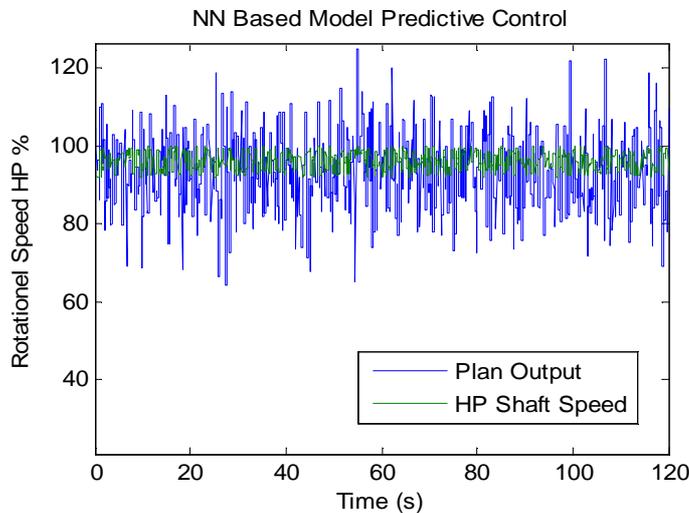


Figure IV.28 : Vitesse de rotation de l'arbre HP avec modèle contrôle de réseaux de neurones

Le résultat du contrôle de prédictive par modèle basé sur le réseau de neurone permet de visualiser les signaux vibratoires mesurés qui entraîne un déséquilibre plus important sur la vibration de rotor de la turbine à gaz examinée. D'après les résultats obtenus par modélisation en utilisant les approches d'activation supervisé de réseaux montrent que l'architecture du réseau est meilleure, car les valeurs de

l'erreur est pratiquement négligeable, ce qui montre que les sorties désirées sont très proches des sorties réelles.

Pour la validation de l'approche proposée de contrôle de vitesse de l'arbre de la turbine HP, on utilise les réseaux de neurones NARX en boucle fermée pour contrôler les signaux vibratoires collectés par les capteurs au niveau des paliers, comme il est montré sur la Figure IV.29

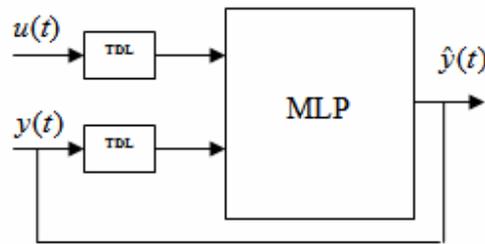


Figure IV.29 : Contrôle des signaux vibratoires de la turbine en boucle fermée

Pour valider notre modèle neuronal, il suffit d'avoir toutes les performances du signal, l'utilisation du réseau NARX en boucle fermée fait l'appel de validation avec leur capacité de prédire une portion du signal pour visualiser la caractéristique du signal.

Les signaux du HP, LP et les signaux du capteur de paliers sont collectés au 12631 unités de temps. Le NARX en boucle ouverte permet de contrôler le signal. Pour la validation, le NARX en boucle fermée fait l'objet par leur capacité de généralisation. Dans notre application le NARX en boucle fermée est chargé de valider le modèle neuronale par la prédiction à long terme dans le temps, comme il est montré sur la Figure IV.30 et IV.31.

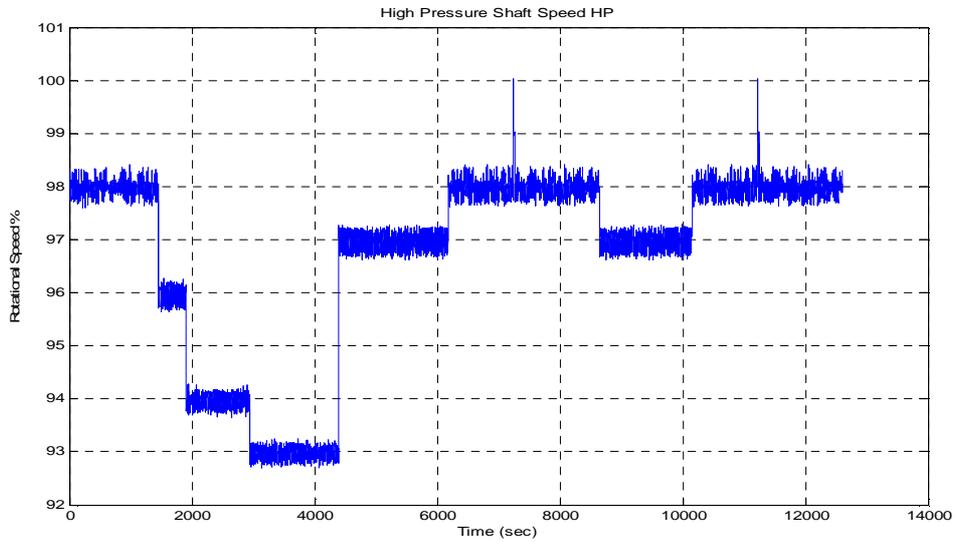


Figure IV.30 : Signaux vibratoire mesurés de la vitesse NGP

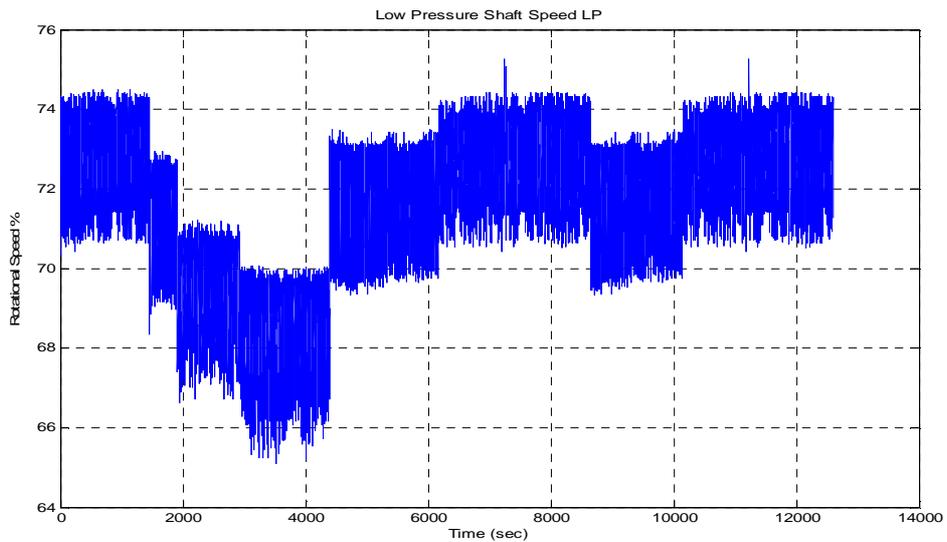
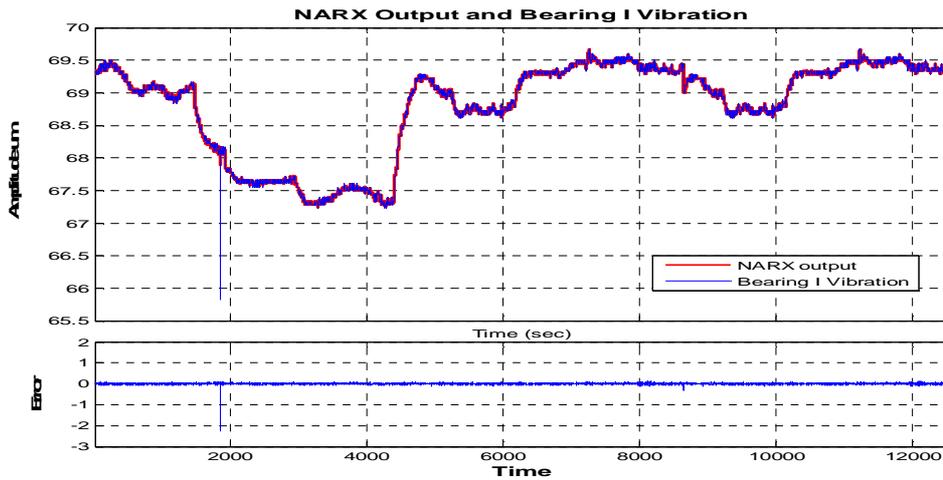


Figure IV.31 : Signaux vibratoire mesurés de la vitesse NPT

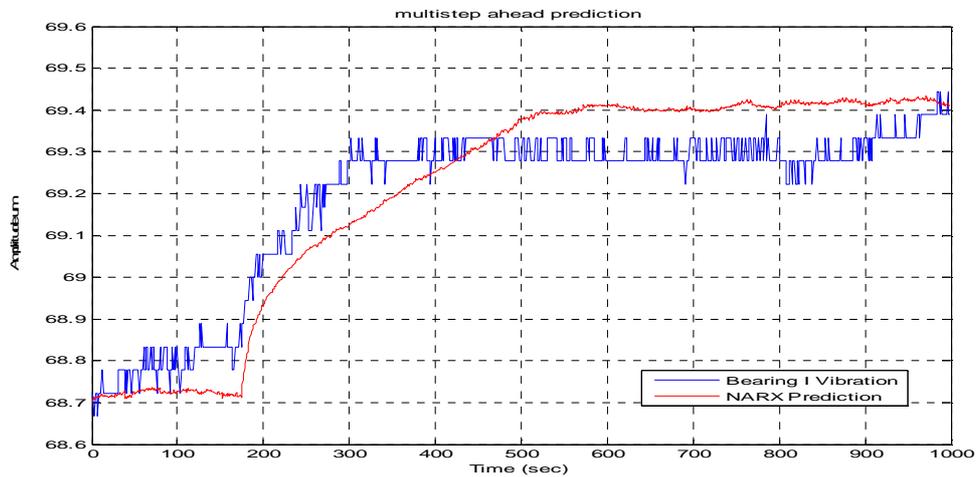
Valider le modèle neuronal proposé dans ce travail a pour objectif d'augmenter les capacités de modélisation du comportement vibratoire de la turbine à gaz examinée. Afin d'étudier le comportement vibratoire de cette turbine, nous donnons le modèle neuronal de vibration de palier N° (01, 02, 03, 04 et 05) comme il est montré sur les Figures IV.32.A, IV.33.A, IV.34.A, IV.35.A et IV.36.A. Cela, permet de

mieux gérer les défaillances causées par les vibrations dans les cinq paliers et permet donc de décrire les paramètres liés aux vibrations et représente l'état du mouvement vibratoire.

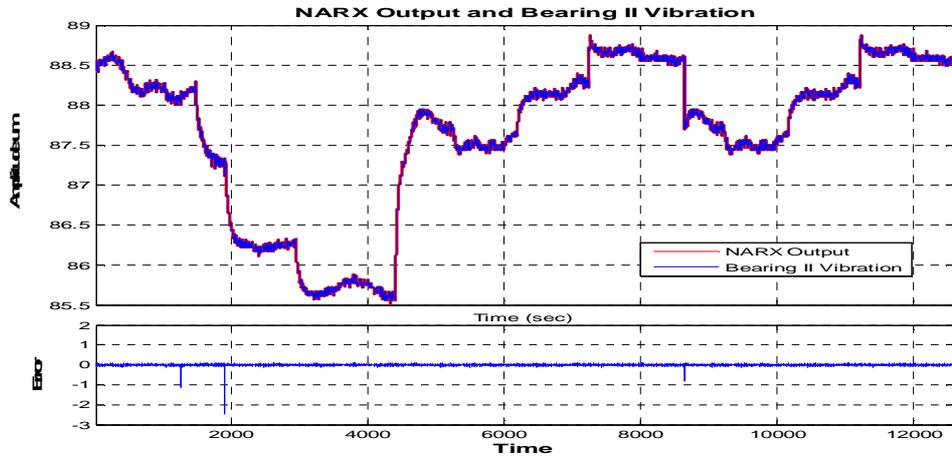
Le modèle neuronal NARAX proposé permet d'estimer la capacité prédictive du réseau neuronal, cela est montré sur les Figures IV.32.B, IV.33.B, IV.34.B, IV.35.B et IV.36.B, ils sont comparés aux valeurs observées des données d'exploitation de turbine étudiée.



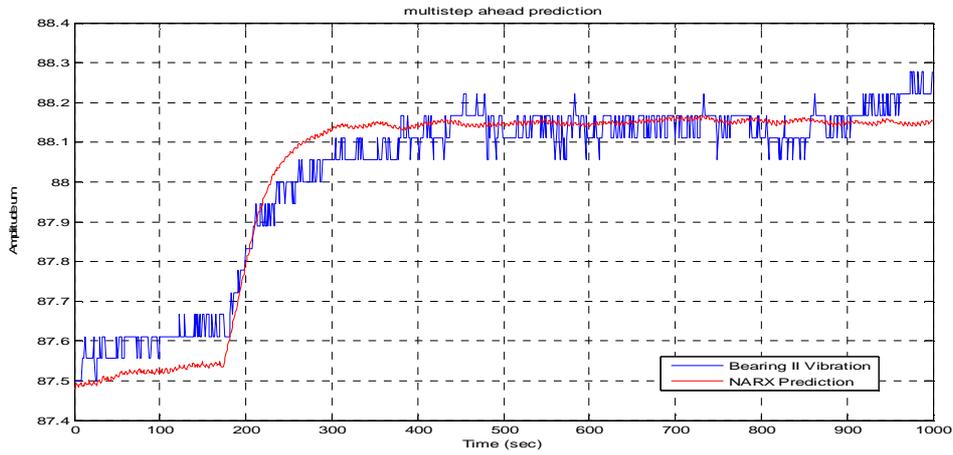
Figures IV.32.A : Réponse du modèle neuronal de vibration de palier N° 01



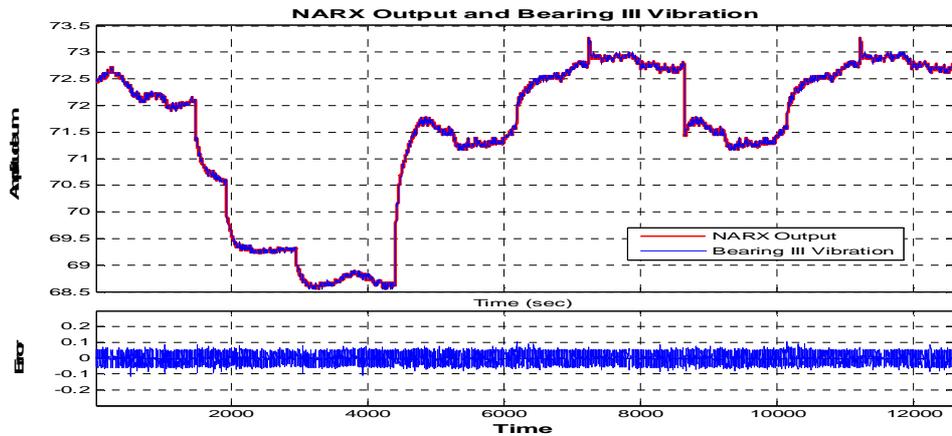
Figures IV.32.B : Prédiction neuronale de vibration de palier N° 01



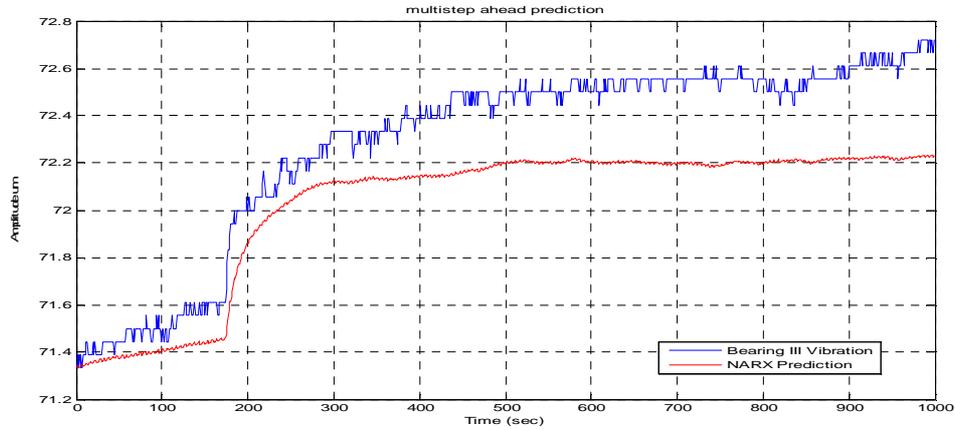
Figures IV.33.A : Réponse du modèle neuronal de vibration de palier N° 02



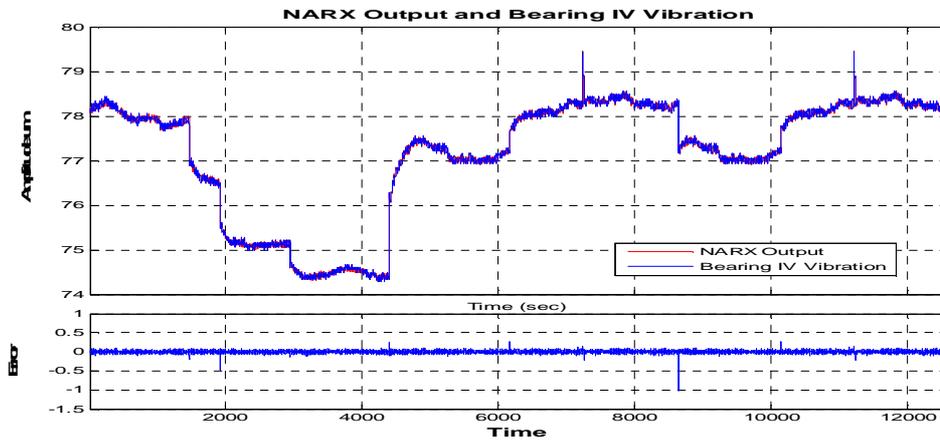
Figures IV.33.B : Prédiction neuronale de vibration de palier N° 02



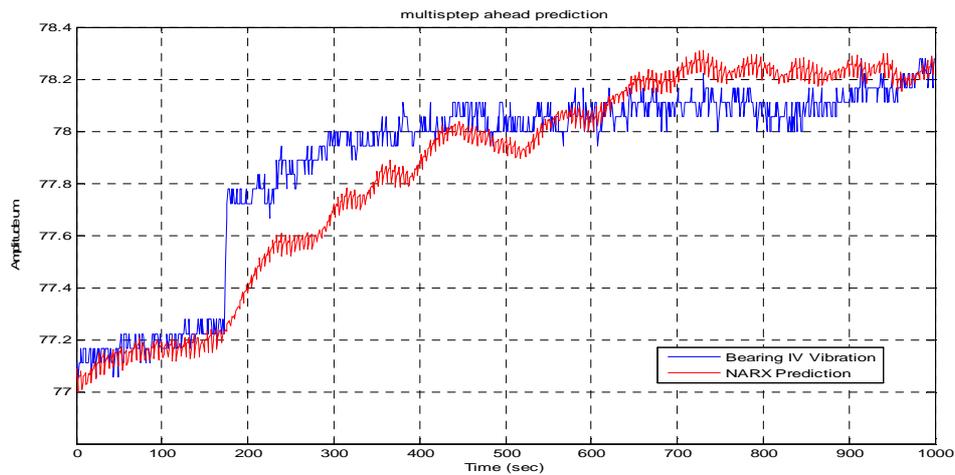
Figures IV.34.A : Réponse du modèle neuronal de vibration de palier N° 03



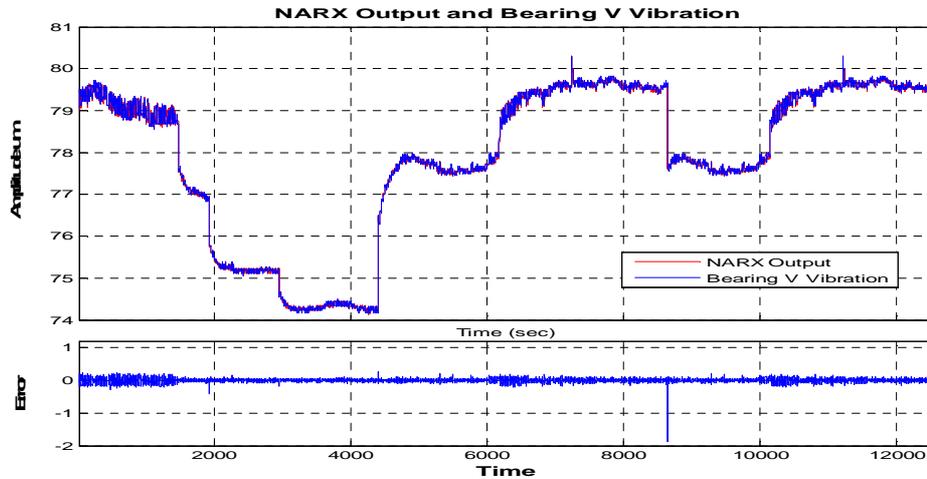
Figures IV.34.B : Prédiction neuronale de vibration de palier N° 03



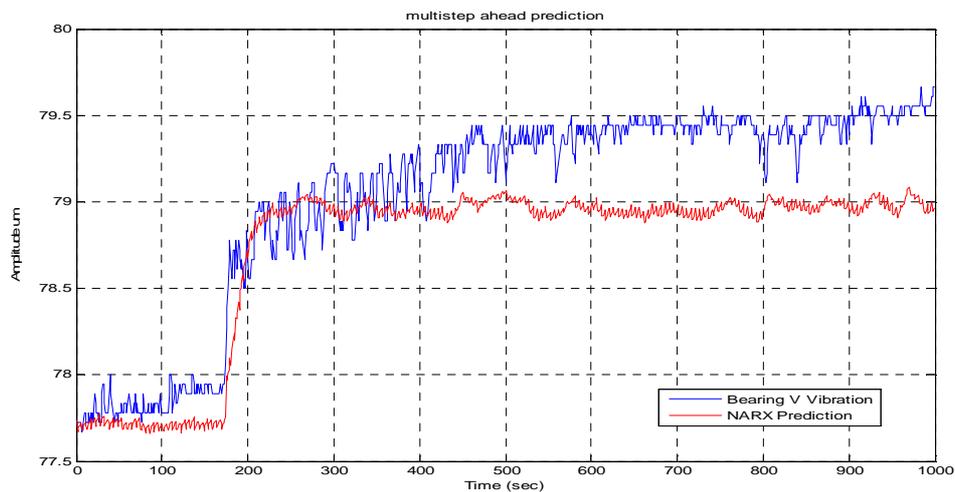
Figures IV.35.A : Réponse du modèle neuronal de vibration de palier N° 04



Figures IV.35.B : Prédiction neuronale de vibration de palier N° 05



Figures IV.36.A : Réponse du modèle neuronal de vibration de palier N° 05



Figures IV.36.B : Prédiction neuronale de vibration de palier N° 05

Les résultats obtenus permettent de montrer la puissance de prédiction de modèle neuronal NARX proposé pour les différents modèles déterminés pour les cinq paliers. Chaque palier a été testé indépendamment. L'analyse et l'interprétation des dégradations dans ces composants de turbine à gaz examinée repose sur des séries de mesures et d'observations des phénomènes anormales, qui permet de modéliser les causes des dégradations, en se basons sur l'évaluation des modèles neuronal de ces composantes à partir des ces mesures. La démarche proposée, basée sur la modélisation neuronal des défauts de vibrations, permet d'améliorer l'analyse du comportement dynamique de la turbine étudiée.

IV.8. Conclusion

Le défi dans ce travail est la modélisation des composantes d'une turbine à gaz utilisant une approche autorégressive non linéaire dynamique avec entrée exogène externe NARX, qui a donné une capacité d'identifier le comportement dynamique de cette turbine avec des bonnes prédictions. Cela permet de tracer et élaborer une stratégie de diagnostics efficace à ce type de machine tournante et fournir un outil très puissant pour les besoins de la maintenance, surtout dans l'industrie pétrolière ou la compétition est exprimée par la qualité et les coûts. Les résultats obtenus, permettent de mieux gérer les défaillances causées par les vibrations et montrant l'efficacité des réseaux de neurones artificiels comme outils de calcul très puissants dans la modélisation des systèmes dynamiques complexes.

Le modèle développé dans ce travail simule le comportement dynamique des rotors d'une turbine à gaz, tournant à haute vitesse, destinée pour entraîner un compresseur du gaz naturel (compresseur centrifuge). Une technique de surveillance par réseaux de neurones à été proposé pour représentant l'état de fonctionnement de ce système. Cette technique présente une analyse très fine des signaux et permet de diagnostiquer des défauts de différentes natures, et dans plusieurs configurations, en mode de fonctionnement en temps réel.

Conclusion générale

À cause de leur utilisation fréquente dans diverses applications, les turbines à gaz nécessitent une détection rapide et précoce de leurs défaillances. Les travaux exposés dans cette thèse appuient essentiellement sur le développement et la validation expérimentale des techniques de diagnostic à base des réseaux de neurones artificiels appliquées à une turbine. Le défi dans cette thèse été l'identification des comportements indésirable des composantes d'une turbine à gaz on utilisant une approche autorégressive non linéaire dynamique avec entrée exogène externe NARX pour donner une possibilité et une capacité à identifier le comportement dynamique de cette turbine avec des bonnes prédictions.

Le but est de créer une stratégie de diagnostics efficace à ce type de machines tournantes et un outil très puissant pour les besoins de la maintenance, surtout dans l'industrie pétrolière où la compétition est exprimée par la qualité et les coûts. Les résultats obtenus doivent permettre de mieux gérer les défaillances causées par les vibrations et montrant l'efficacité des réseaux de neurones artificiels comme outils de calcul très puissants dans la modélisation des systèmes dynamiques complexes.

Notre travail a donc apporté quelques éléments méthodologiques, les résultats obtenus à partir de l'étude réalisée sur un système de turbine à gaz reflétant leur comportement dynamique. Ces résultats basés sur une approche de diagnostic proposé ont été testés ensuite validés avec des erreurs de prédiction convergente vers zéro. Cette approche a permit de modéliser les actes de dégradation par vibrations des composants de la turbine à gaz examinée et d'estimer et planifier la durée de dysfonctionnement de ce système de turbine à gaz.

Le modèle développé dans ce travail a donc simulé le comportement dynamique de cette turbine tournant à haute vitesse, destinée à conduire un compresseur centrifuge utilisé dans le transport de gaz naturel. Une approche de surveillance utilisant les réseaux de neurones proposée a bien donné une réponse sollicitée à partir de la variable d'entrée (défauts de vibration) pour caractériser les variables de sortie représentant l'état de fonctionnement de ce système. Cette technique présente une analyse très fine des défauts de vibrations et permet de diagnostiquer des défauts de natures différentes dans plusieurs configurations, en mode de fonctionnement en temps réel.

La modélisation des composantes de turbine à gaz on utilisant une approche autorégressive non linéaire dynamique avec entrée exogène externe NARX à été réalisé et a donné une possibilité et une capacité à identifier le comportement dynamique de cette turbine avec des bonnes prédictions. Cela nous a permet d'élaborer une stratégie de diagnostics efficace à ce type de machines tournantes et fournir un outil très puissant pour les besoins de maintenance. Les résultats obtenus montrant alors de mieux gérer les défaillances causées par les vibrations et montrant l'efficacité des réseaux de neurones artificiels comme outils de calcul très puissants dans la modélisation des systèmes dynamiques complexes.

Enfin, les résultats obtenus montrent que les réseaux de neurones dédiés à l'estimation des variables de la turbine examinée ont été parfaitement modélisés en utilisant le système NARX proposé. Ils permettent de présenter le comportement dynamique de cette machine et assurant leur fonctionnement optimale. Ces résultats montrent qu'utiliser une modélisation avec l'approche NARX pour la turbine étudié est très important et un effet bénéfique surtout avec une plus forte influence des données utilisées selon leurs contenu et qualité qui peuvent apportées des modèles améliorés. Le modèle de l'arbre de turbine à haute pression HP avec son modèle NARX a fournit des outils de surveillance pratique les plus adaptés pour la modélisation de la turbine à gaz MS 3002 examinée.

Nous pensons que les contributions présentées dans cette thèse ouvrent de nouvelles perspectives et des travaux restent à faire afin d'améliorer ces modèles et de facilité leurs utilisation. Nous pensons bien que les points suivants peuvent être améliorés :

1. Problèmes de robustesse des approches de diagnostic utilisant les techniques d'intelligence artificielle,
2. Amélioration des performances de stratégie de diagnostic en utilisant les réseaux de neurones, en se basant sur le concept flou pour l'optimisation des fonctions d'activation neurone,
3. Formulation d'un modèle plus précis de la turbine à gaz à deux arbres

Bibliographie

- [1]. Ahmed Hafaifa, Guemana Mouloud and Belhadeif Rachid, Fuzzy Modeling and Control of Centrifugal Compressor Used in Gas Pipelines Systems. *Multiphysics Modelling and Simulation for Systems Design and Monitoring, Applied Condition Monitoring Vol 2*, 2015, pp 379-389.
- [2]. Ahmed Hafaifa, Mouloud Guemana and Attia Daoudi, Fault detection and isolation in industrial systems based on spectral analysis diagnosis. *Intelligent Control and Automation*, February 2013, vol. 4, pp. 36-41.
- [3]. Ahmed Hafaifa, Mouloud Guemana and Attia Daoudi, Vibration supervision in gas turbine based on parity space approach to increasing efficiency. *Journal of Vibration and Control*, 2015, vol. 21, pp.1622-1632.
- [4]. Ahmed Hafaifa, Mouloud Guemana and Saadat Boulanouar, Monitoring system based on real data acquisition for vibrations control in gas turbine system. *Revue de Nature & Technologie: A- Sciences fondamentales et Engineering*, Janvier 2016, n° 14, pp. 13 – 18.
- [5]. Ahmed Zohair Djeddi, Ahmed Hafaifa, Abudura Salam, Gas turbine reliability model based on tangent hyperbolic reliability function. *Journal of Theoretical and Applied Mechanics*, 2015, vol. 53, no. 3, pp. 723-730.
- [6]. Ailer P., Santa I., Szederkenyi G. and Hangos K.M., Nonlinear model-building of a low-power gas turbine, *Periodica Polytechnica Series on Transportation Engineering*, 2001, vol. 32, pp. 117-135.
- [7]. Alfredo Ursúa, Pablo Sanchis, Static–dynamic modelling of the electrical behaviour of a commercial advanced alkaline water electrolyser. *International Journal of Hydrogen Energy*, 2012, vol. 37, no. 24, pp. 18598-18614.
- [8]. Amozegar M., Khorasani K., An ensemble of dynamic neural network identifiers for fault detection and isolation of gas turbine engines. *Neural Networks*, 2016, vol. 76, pp. 106-121.
- [9]. Arkov V.Y., Kulikov G.G., Breikin T.V., Life cycle support for dynamic modelling of gas turbines. *Proceedings of the 15th Triennial IFAC World Congress, Barcelona, Spain; 2002*, pp. 2135-2140.

- [10]. Ashwani Kumar, Arpit Dwivedi, Vipul Paliwal, Pravin P. Patil, Free Vibration Analysis of AI 2024 Wind Turbine Blade Designed for Uttarakhand Region based on FEA. *Procedia Technology*, 2014, vol. 14, pp. 336-347.
- [11]. Balamurugan S., Janarthanan N., Vijaya Chandrakala K.R.M., Small and large signal modeling of heavy duty gas turbine plant for load frequency control. *International Journal of Electrical Power & Energy Systems*, 2016, vol. 79, pp. 84-88.
- [12]. Barsali S., De Marco A., Giglioli R., Ludovici G., Possenti A., Dynamic modelling of biomass power plant using micro gas turbine. *Renewable Energy*, 2015, vol. 80, pp. 806-818.
- [13]. Bartolini C.M., Caresana F., Comodi G., Pelagalli L., Renzi M., Vagni S., Application of artificial neural networks to micro gas turbines. *Energy Conversion and Management*, 2011, vol. 52, no. 1, pp. 781-788.
- [14]. Ben Rahmoune Mohamed, Ahmed Hafaifa and Guemana Mouloud, Vibration modeling improves pipeline performance, costs. *Oil & Gas Journal*, Mars 2015, pp. 98-100.
- [15]. Benrabe Djaidir, Ahmed Hafaifa and Abdallah Kouzou, Performance control of gas turbines. *Turbomachinery International Journal*, November 2015, November 2015, pp.10-14.
- [16]. Benrabe Djaidir, Ahmed Hafaifa and Abdallah Kouzou, Monitoring Gas Turbines Using Speedtronic Mark VI Control Systems. *Pipeline & Gas Journal*, October 2015, vol. 242, no. 10, pp.48-86.
- [17]. Benrabe Djaidir, Ahmed Hafaifa and Abdallah Kouzou, Rotor vibration dynamic analysis helps detect compressor defects. *Oil & Gas Journal*, 2016, vol. 114, no. 7, pp. 64-69.
- [18]. Benrabe Djaidir, Ahmed Hafaifa and Kouzou Abdallah, Faults detection in gas turbine rotor using vibration analysis under varying conditions. *Journal of Theoretical and Applied Mechanics*, 2017, vol. 55, no. 2, pp. 393-406.
- [19]. Benrabe Djaidir, Ahmed Hafaifa and Kouzou Abdallah, Monitoring gas turbines using speedtronic Mark VI control systems. *Pipeline & Gas Journal*, 2015, vol. 242, no. 10, pp.48-86.
- [20]. Benrabe Djaidir, Ahmed Hafaifa, Abdallah Kouzou, Vibration Detection in Gas Turbine Rotor Using Artificial Neural Network Combined with Continuous Wavelet. *Book Chapter in Advances in Acoustics and Vibration*, 2017, vol. 5, 101-113.
- [21]. Besir Dandil, Muammer Gokbulut and Fikret Ata, A PI Type Fuzzy-neural Network Controller for Induction Motor Drives, *Journal of Applied Sciences*, 2005, vol. 5, no. 7, pp. 1286-1291.

- [22]. Boulanouar Saadat, Ahmed Hafaifa and Mouloud Guemana, Vibration analysis and measurement based on defect signal evaluation: Gas turbine investigation. *Journal of Advanced Research in Science and Technology*, 2016, vol. 3, no 1, pp.271-280.
- [23]. Breikin T.V., Arkov V.Y., Kulikov G.G., Application of Markov chains to identification of gas turbine engine dynamic models. *International Journal of Systems Science*, 2006, vol. 73, no. 3, pp. 197-205.
- [24]. Chang R.J., Two-stage optimal stochastic linearization in analyzing of non-linear stochastic dynamic systems. *International Journal of Non-Linear Mechanics*, 2014, vol. 58, pp. 295-304.
- [25]. Chen J., R. J. Patton, and H. Y. Zhang, Design of unknown input observer and robust fault detection filters. *International Journal of Control*, 1996, vol. 63, no. 1, pp. 85-105.
- [26]. Chen W. and Saif M., Adaptive actuator fault detection, isolation and accommodation in uncertain systems. *International Journal of Control*, 2007, vol. 80, no. 1, pp. 45-63.
- [27]. Chen Y.M., Lee M.L. (2002). Neural networks-based scheme for system failure detection and diagnosis. *Mathematics and Computers in Simulation*, vol. 58, no. 2, pp. 101-109.
- [28]. Chih-Cheng. Tsai , Rotating vibration behavior of the turbine blades with different groups of blades. *Journal of Sound and Vibration*, 2004, vol. 271, no. 3-6, pp. 547-575.
- [29]. Chii-Shang Tsai, Chuei-Tin Chang, Dynamic process diagnosis via integrated neural networks. *Computers & Chemical Engineering*, 1995, vol. 19, no. 1, pp. 747-752.
- [30]. Chiong M.S., Rajoo S., Romagnoli A., Costall A.W., Martinez-Botas R.F., Non-adiabatic pressure loss boundary condition for modelling turbocharger turbine pulsating flow. *Energy Conversion and Management*, 2015, vol. 93, pp. 267-281.
- [31]. Chiung Yu Huang and Robert Stengel, Restructurable control using proportional-integral implicit model following. *Control et Dynamics*, 1990, vol. 2, pp. 303-309.
- [32]. Chow E.Y. and Willsky A.S., Analytical redundancy and the design of robust failure detection systems. *IEEE Transaction on Automatic Control*, 1984, vol. 29, pp. 603-614.
- [33]. Combescure D., Lazarus A., Refined finite element modelling for the vibration analysis of large rotating machines: Application to the gas turbine modular helium reactor power conversion unit. *Journal of Sound and Vibration*, vol. 318, no. 4–5, 2008, pp. 1262-1280.
- [34]. Corrado Chisari, Chiara Bedon, Claudio Amadio, Dynamic and static identification of base-isolated bridges using Genetic Algorithms. *Engineering Structures*, 2015, vol. 102, pp. 80-92.

- [35]. Cruz H. de la, Biscay R.J., Jimenez J.C., Carbonell F., Local Linearization—Runge–Kutta methods: A class of A-stable explicit integrators for dynamical systems. *Mathematical and Computer Modelling*, 2013, vol. 57, no. 3-4, pp. 720-740.
- [36]. Duan Y., Sun L., Wang G., Wu F., Nonlinear modeling of regenerative cycle micro gas turbine. *Energy*, 2015, vol. 91, pp. 168-175.
- [37]. Eckart Uhlmann, David Carlos Domingos, Investigations on Vibration-assisted EDM-machining of Seal Slots in High-Temperature Resistant Materials for Turbine Components –Part II. *Procedia CIRP*, 2016, vol. 42, pp. 334-339.
- [38]. Ehsan Mohammadi, Morteza Montazeri-Gh, A fuzzy-based gas turbine fault detection and identification system for full and part-load performance deterioration. *Aerospace Science and Technology*, 2015, vol. 46, pp. 82-93.
- [39]. El Hamzaoui Y., Rodríguez J.A., Hernández J.A., Victor Salazar, Optimization of operating conditions for steam turbine using an artificial neural network inverse. *Applied Thermal Engineering*, 2015, vol. 75, pp. 648-657.
- [40]. Ewins D.J., Control of vibration and resonance in aero engines and rotating machinery – An overview. *International Journal of Pressure Vessels and Piping*, vol. 87, no. 9, 2010, pp. 504-510.
- [41]. Fabian G. Pierart, Ilmar F. Santos, Lateral vibration control of a flexible overcritical rotor via an active gas bearing – Theoretical and experimental comparisons. *Journal of Sound and Vibration*, 2016, vol. 383, pp. 20-34.
- [42]. Farrahi G.H., Tirehdast M., Masoumi Khalil Abad E., Parsa S., Motakefpoor M., Failure analysis of a gas turbine compressor. *Engineering Failure Analysis*, 2011, vol. 18, no. 1, pp. 474-484.
- [43]. Fast M., Assadi M., De S., Development and multi-utility of an ANN model for an industrial gas turbine. *Applied Energy*, 2009, vol. 86, no. 1, pp. 9-17.
- [44]. Fatima Bekaddour, Mohamed Ben Rahmoune, Chikhi Salim and Ahmed Hafaifa, Performance Study of Different Metaheuristics for Diabetes Diagnosis., (eds) *Advances in Computational Intelligence. IWANN 2017. Lecture Notes in Computer Science*, vol 10305, pp 591-602, 18 May 2017, DOI: 10.1007/978-3-319-59153-7_51
- [45]. Fengming Shi, Ron Patton, An active fault tolerant control approach to an offshore wind turbine model. *Renewable Energy*, 2015, vol. 75, pp. 788-798.

- [46]. Feyzullah Temurtas. (2009). A comparative study on thyroid disease diagnosis using neural networks. *Expert Systems with Applications*, vol. 36, no. 1, pp. 944-949.
- [47]. Frank P. M. and Ding X., Survey of robust residual generation and evaluation methods in observer-based fault detection systems. *Journal of Process Control*, 1997, vol. 7, no. 6, pp. 403-424.
- [48]. Frank P.M, Alcorta-Garcia.E et Köppen-Seliger, Modelling for fault detection and isolation versus modelling for control. *Mathematical and Computer Modelling of Dynamical Systems*, 2001, vol. 7, no. 1, pp. 1-46.
- [49]. Gareth L. Forbes, Robert B. Randall, Estimation of turbine blade natural frequencies from casing pressure and vibration measurements. *Mechanical Systems and Signal Processing*, 2013, vol. 36, no. 2, pp. 549-561.
- [50]. Gertler J.J., Kunwer M.M., Optimal residual decoupling for robust fault diagnosis. *International Journal of Control*, 1995, vol. 61, no. 2, pp. 395-421.
- [51]. Gertler Janos J., Analytical redundancy methods in failure detection and isolation in complex plants. *Control Theory and Advanced Technology*, 1993, vol. 9, no. 1, pp. 259-285.
- [52]. Grzegorz Nowak, Andrzej Rusin, Using the artificial neural network to control the steam turbine heating process. *Applied Thermal Engineering*, 2016, vol. 108, pp. 204-210.
- [53]. Guasch A., Quevedo J., Milne R., Fault diagnosis for gas turbines based on the control system. *Engineering Applications of Artificial Intelligence*, 2000, vol. 13, no. 4, pp. 477-484.
- [54]. Günyaz Ablay, A modeling and control approach to advanced nuclear power plants with gas turbines. *Energy Conversion and Management*, 2013, vol. 76, pp. 899-909.
- [55]. Gwo-Chung Tsai, Rotating vibration behavior of the turbine blades with different groups of blades. *Journal of Sound and Vibration*, 2004, vol. 271, no. (3-5, 6), pp. 547-575.
- [56]. Hamid Asgari, XiaoQi Chen, Mirko Morini, Michele Pinelli, Raazesh Sainudiin, Pier Ruggero Spina, Mauro Venturini, NARX models for simulation of the start-up operation of a single-shaft gas turbine. *Applied Thermal Engineering*, 2016, vol. 93, pp. 368-376.
- [57]. Hasan Abbasi Nozari, Mahdi Aliyari Shoorehdeli, Silvio Simani, Hamed Dehghan Banadaki, Model based robust fault detection and isolation of an industrial gas turbine prototype using soft computing techniques. *Neurocomputing*, 2012, vol. 91, pp. 29-47.

- [58]. Heydar Pendar, Mehdi Mohammad Salehi, Riyaz Kharrat, Saeed Zarezadeh, Numerical and ANFIS modeling of the effect of fracture parameters on the performance of VAPEX process. *Journal of Petroleum Science and Engineering*, 2016, vol. 143, pp. 128-140.
- [59]. Hossein Shayeghi, Behrooz Sobhani, Elnaz Shahryari, Adel Akbarimajd, Optimal neuro-fuzzy based islanding detection method for Distributed Generation. *Neurocomputing*, 2016, vol. 77, pp. 478-488.
- [60]. Hosseinalipour S. M., Razaghi E. and Abdolahi M., Static and Dynamic Mathematical Modeling of a Micro Gas Turbine, *Journal of Mechanics*, 2013, vol. 29, no. 2, pp. 327-336.
- [61]. Houman Hanachi, Jie Liu, Avisekh Banerjee, Ying Chen, Sequential state estimation of nonlinear/non-Gaussian systems with stochastic input for turbine degradation estimation. *Mechanical Systems and Signal Processing*, 2016, vol. 72–73, pp. 32-45.
- [62]. Huang C.Y. and Stengel R., Restructurable control using proportional-integral implicit model following. *Journal of Guidance, Control et Dynamics*, 1990, vol. 13, no. 2, pp. 303-309.
- [63]. Isermann R. and Balle P., Trends in the application of model-based fault detection and diagnosis of technical processes, *Control Engineering Practice*, 1997, vol. 5, pp. 709-719.
- [64]. Isermann, R., Process fault detection based on modeling and estimation methods: a survey. *Automatica Journal*, vol. 20, pp. 387-404, 1984.
- [65]. Jakub Cichowicz, Gerasimos Theotokatos, Dracos Vassalos, Dynamic energy modelling for ship life-cycle performance assessment. *Ocean Engineering*, 2015, vol. 110, Part B, pp. 49-61.
- [66]. Jiandong Duan, Li Sun, Guanglin Wang, Fengjiang Wu, Nonlinear modeling of regenerative cycle micro gas turbine. *Energy*, 2015, vol. 91, pp. 168-175.
- [67]. Jianglin Lan, Ron J. Patton, A new strategy for integration of fault estimation within fault-tolerant control. *Automatica*, 2016, vol. 69, pp. 48-59.
- [68]. Jianxiong Ye, Enmin Feng, Hansheng Lian, Zhilong Xiu, Existence of equilibrium points and stability of the nonlinear dynamical system in microbial continuous cultures. *Applied Mathematics and Computation*, 2009, vol. 207, no. 2, pp. 307-318.
- [69]. Ji-Zhen Liu, Shu Yan, De-Liang Zeng, Yong Hu, You Lv, A dynamic model used for controller design of a coal fired once-through boiler-turbine unit. *Energy*, 2015, vol. 93, Part 2, pp. 2069-2078.

- [70]. Joly R.B., Ogaji S.O.T., Singh R., Probert S.D., Gas-turbine diagnostics using artificial neural-networks for a high bypass ratio military turbofan engine. *Applied Energy*, 2004, vol. 78, no. 4, pp. 397-418.
- [71]. Joseph McGhee, Ian A. Henderson, Alistair Baird. (1997). Neural networks applied for the identification and fault diagnosis of process valves and actuators. *Measurement*, vol. 20, no. 4, pp. 267-275.
- [72]. Jurado F., Carpio J., Improving distribution system stability by predictive control of gas turbines. *Energy Conversion and Management*, Volume 47, Issues 18–19, November 2006, Pages 2961-2973.
- [73]. Karim Salahshoor, Majid Soleimani Khoshro, Mojtaba Kordestani, Fault detection and diagnosis of an industrial steam turbine using a distributed configuration of adaptive neuro-fuzzy inference systems. *Simulation Modelling Practice and Theory*, 2011, vol. 19, no. 5, pp. 1280-1293.
- [74]. Karim Salahshoor, Mojtaba Kordestani, Design of an active fault tolerant control system for a simulated industrial steam turbine. *Applied Mathematical Modelling*, 2014, vol. 38, no. 5-6, pp. 1753-1774.
- [75]. Karim Salahshoor, Mojtaba Kordestani, Majid S. Khoshro, Fault detection and diagnosis of an industrial steam turbine using fusion of SVM (support vector machine) and ANFIS (adaptive neuro-fuzzy inference system) classifiers. *Energy*, 2010, vol. 35, no. 12, pp. 5472-5482.
- [76]. Kulikov GG. Dynamic characteristic of gas turbine engine. In: Shevyakov AA, Martyanova TS, editors. *Optimisation of Multivariable Control Systems of Aero Gas Turbine Engines*. (In Russian). Moscow, Book edited by Mashinostroenie, 1989, pp. 35-41.
- [77]. Kulikov GG. Methods for creation of linear mathematical models of gas turbine engines, In: Shevyakov AA, Martyanova TS, editors. *Optimisation of Multivariable Control Systems of Aero Gas Turbine Engines*. (In Russian). Moscow, Book edited by Mashinostroenie, 1989, pp. 41-81.
- [78]. Kulikov GG. Nonlinear performance-based static and dynamic models of gas turbine engines. In: Shevyakov AA, Martyanova TS, editors. *Optimisation of Multivariable Control Systems of Aero Gas Turbine Engines*. (In Russian). Moscow: Mashinostroenie, 1989, pp. 30-35.

- [79]. Kyoung Hoon Kim, Hyung-Jong Ko, Horacio Perez-Blanco, Analytical modeling of wet compression of gas turbine systems. *Applied Thermal Engineering*, Volume 31, Issue 5, April 2011, Pages 834-840
- [80]. Leger R.P., Garland Wm.J., Poehlman W.F.S. (1998). Fault detection and diagnosis using statistical control charts and artificial neural networks. *Artificial Intelligence in Engineering*, vol. 12, no. 1–2, pp. 35-47.
- [81]. Liang-Ying Wei, A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting. *Applied Soft Computing*, 2016, vol. 42, pp. 368-376.
- [82]. Lyantsev O.D., Breikin T.V., Kulikov G.G., Arkov V.Y., Optimal multi-variable control of gas turbine engines. *International Journal of Systems Science*, 2004, vol. 35, no. 2, pp. 79-86.
- [83]. Madhavan S., Rajeev Jain, Sujatha C., Sekhar A.S., Vibration based damage detection of rotor blades in a gas turbine engine. *Engineering Failure Analysis*, 2014, vol. 46, pp. 26-39.
- [84]. Martha A. Zaidan, Andrew R. Mills, Robert F. Harrison, Peter J. Fleming, Gas turbine engine prognostics using Bayesian hierarchical models: A variational approach. *Mechanical Systems and Signal Processing*, 2016, vol. 70–71, pp. 120-140.
- [85]. Nadji Hadroug, Ahmed Hafaifa and Mouloud Guemana, Detect faults in gas turbine installation, using adaptive network with fuzzy inference. *Hydrocarbon Processing Journal / Gas Processing* | 2017, vol. MARCH/APRIL 2017.
- [86]. Nadji Hadroug, Ahmed Hafaifa, Abdellah Kouzou and Ahmed Chaibet, Faults detection in gas turbine using hybrid adaptive network based fuzzy inference systems to controlling there dynamic behavior. *DIAGNOSTYKA the Journal of Polish Society of Technical Diagnostics (PSTD)*, 2016, vol. 17, no. 4, pp. 3-17.
- [87]. Nadji Hadroug, Ahmed Hafaifa, Abdellah Kouzou, Mouloud Guemana and Ahmed Chaibet, Control of the speed and exhaust gas temperature in gas turbine using adaptive neuro-fuzzy inference system. *Journal of Automation & Systems Engineering*, 2016, vol. 10, no. 3, pp. 158-167.
- [88]. Nadji Hadroug, Ahmed Hafaifa, Kouzou Abdellah and Ahmed Chaibet, Dynamic model linearization of two shafts gas turbine via their input / output data around the equilibrium points. *Energy Elsevier*, 2017, vol. 120, pp. 488-497.

- [89]. Narendra Kumpati.S and Parthasarathy K., Identification and Control of Dynamical Systems using Neural Networks, IEEE Trans. on Neural Networks, Vol. NO. 1, 1990, pp.4-27.
- [90]. Nikolaus A. Bornhöft, Tian Yin Sun, Lorenz M. Hilty, Bernd Nowack, A dynamic probabilistic material flow modeling method. Environmental Modelling & Software, 2016, vol. 76, pp. 69-80.
- [91]. Nikpey H., Assadi M., Breuhaus P., Development of an optimized artificial neural network model for combined heat and power micro gas turbines. Applied Energy, 2013, vol. 108, pp. 137-148.
- [92]. Nikpey H., Assadi M., Breuhaus P., Mørkved P.T., Experimental evaluation and ANN modeling of a recuperative micro gas turbine burning mixtures of natural gas and biogas. Applied Energy, vol. 117, 2014, pp. 30-41.
- [93]. Ogaji S.O.T., Singh R., Probert S.D., Multiple-sensor fault-diagnoses for a 2-shaft stationary gas-turbine. Applied Energy, 2002, vol. 71, no. 4, pp. 321-339.
- [94]. Orhan Er, Nejat Yumusak, Feyzullah Temurtas, Chest diseases diagnosis using artificial neural networks. Expert Systems with Applications, 2010, vol. 37, no. 12, pp.7648-7655.
- [95]. Pak Kin Wong, Zhixin Yang, Chi Man Vong, Jianhua Zhong, Real-time fault diagnosis for gas turbine generator systems using extreme learning machine. Neurocomputing, 2014, vol. 128, pp. 249-257.
- [96]. Peter Turney and Michael Halasz, Contextual normalization applied to aircraft gas turbine engine diagnosis. Applied Intelligence, 1993, vol. 3, no. 2, pp. 109-129.
- [97]. Qiannan Zhu, Xianglong Luo, Bingjian Zhang, Ying Chen, Songping Mo, Mathematical modeling, validation, and operation optimization of an industrial complex steam turbine network-methodology and application. Energy, 2016, vol. 97, pp. 191-213.
- [98]. Razak A.M.Y., Gas turbine performance modelling, analysis and optimisation. Modern Gas Turbine Systems, Book Chapter, 2013, pp. 423-514.
- [99]. Ringwood J.V., Simani S., Overview of modelling and control strategies for wind turbines and wave energy devices: Comparisons and contrasts. Annual Reviews in Control, 2015, vol. 40, pp. 27-49.
- [100]. Rösner M., Lammering R., Friedrich R., Dynamic modeling and model order reduction of compliant mechanisms. Precision Engineering, 2015, vol. 42, pp. 85-92.

- [101]. Sadough Vanini Z.N., Khorasani K., Meskin N., Fault detection and isolation of a dual spool gas turbine engine using dynamic neural networks and multiple model approach. *Information Sciences*, 2014, vol. 259, pp. 234-251.
- [102]. Saeed R.A., Galybin A.N., Popov V., 3D fluid–structure modelling and vibration analysis for fault diagnosis of Francis turbine using multiple ANN and multiple ANFIS. *Mechanical Systems and Signal Processing*, 2013, vol. 34, no. 1-2, pp. 259-276.
- [103]. Sanjay Barad G., Ramaiah P.V., Giridhar R.K., Krishnaiah G., Neural network approach for a combined performance and mechanical health monitoring of a gas turbine engine. *Mechanical Systems and Signal Processing*, 2012, vol. 27, pp. 729-742.
- [104]. Sepehr Sanaye, Mojtaba Tahani, Analysis of gas turbine operating parameters with inlet fogging and wet compression processes. *Applied Thermal Engineering*, Volume 30, Issues 2–3, February 2010, Pages 234-244
- [105]. Sierra-Espinosa F.Z., García J.C., Vibration failure in admission pipe of a steam turbine due to flow instability. *Engineering Failure Analysis*, 2013, vol. 27, pp. 30-40.
- [106]. Simani S., Patton Ron J., Fault diagnosis of an industrial gas turbine prototype using a system identification approach. *Control Engineering Practice*, Volume 16, Issue 7, July 2008, Pages 769-786
- [107]. Sina Tayarani-Bathaie S., Khorasani K., Fault detection and isolation of gas turbine engines using a bank of neural networks. *Journal of Process Control*, 2015, vol. 36, pp. 22-41.
- [108]. Sina Tayarani-Bathaie S., Sadough Vanini Z.N., Khorasani K., Dynamic neural network-based fault diagnosis of gas turbine engines. *Neurocomputing*, 2014, vol. 125, pp. 153-165.
- [109]. Sipeng Zhu, Kangyao Deng, Sheng Liu, Modeling and extrapolating mass flow characteristics of a radial turbocharger turbine. *Energy*, 2015, vol. 87, pp. 628-637.
- [110]. Soheil Ghabraei, Hamed Moradi, Gholamreza Vossoughi, Multivariable robust adaptive sliding mode control of an industrial boiler–turbine in the presence of modeling imprecisions and external disturbances: A comparison with type-I servo controller. *ISA Transactions*, 2015, vol. 58, pp. 398-408.
- [111]. Srinivas Kumar Sinha, —Dynamic characteristics of a flexible bladed-rotor with Coulomb damping due to tip-rub, *Journal of Sound and Vibration*, vol. 273, no. 4-5, pp. 875–919, 2004.

- [112]. Staino A., Basu B., Dynamics and control of vibrations in wind turbines with variable rotor speed. *Engineering Structures*, 2013, vol. 56, pp. 58-67.
- [113]. Wahba E.M., Nawar H., Multiphase flow modeling and optimization for online wash systems of gas turbines. *Applied Mathematical Modelling*, Volume 37, Issues 14–15, August 2013, pp. 7549-7560.
- [114]. Wei Sun, Xin Ding, Jing Wei, Xiaobang Wang, Aiqiang Zhang, Hierarchical modeling method and dynamic characteristics of cutter head driving system in tunneling boring machine. *Tunnelling and Underground Space Technology*, 2016, vol. 52, pp. 99-110.
- [115]. Willsky Alan S., A survey of design methods for failure detection in dynamic systems. *Automatica*, 1976, vol. 12 no. 6, pp. 601-611.
- [116]. Xiao-Juan Wu, Qi Huang, Xin-Jian Zhu, Thermal modeling of a solid oxide fuel cell and micro gas turbine hybrid power system based on modified LS-SVM. *International Journal of Hydrogen Energy*, Vol. 36, Issue 1, January 2011, pp. 885-892
- [117]. Yang Chen, Guobiao Cai, Zhenpeng Zhang, Yulong Huang, Multi-field coupling dynamic modeling and simulation of turbine test rig gas system. *Simulation Modelling Practice and Theory*, 2014, vol. 44, pp. 95-118.
- [118]. Yang L., Entchev E., Performance prediction of a hybrid micro-generation system using Adaptive Neuro-Fuzzy Inference System (ANFIS) technique. *Applied Energy*, 2014, vol. 134, pp. 197-203.
- [119]. Yang S.H., Chen B.H., Wang X.Z., Neural network based fault diagnosis using unmeasurable inputs. *Engineering Applications of Artificial Intelligence*, 2000, vol. 13, no. 3, pp. 345-356.
- [120]. Young Sik Kim, Jong Jun Lee, Tong Seop Kim, Jeong L. Sohn, Yong Jin Joo, Performance analysis of a syngas-fed gas turbine considering the operating limitations of its components. *Applied Energy*, Volume 87, Issue 5, May 2010, pp. 1602-1611.
- [121]. Zhang J., Morris A.J., Montague G.A. (1994). Fault diagnosis of a cstr using fuzzy neural networks. *Annual Review in Automatic Programming*, vol. 19, pp. 153-158.
- [122]. Zhao Q. and Jiang J., Reliable state feedback control systems design against actuator failures. *Automatica*, 1998, vol. 34, no. 10, pp. 1267-1272.
- [123]. Zhiyao Ma, Shaocheng Tong, Yongming Li, Fuzzy adaptive state-feedback fault-tolerant control for switched stochastic nonlinear systems with faults. *Neurocomputing*, 2016, vol. 186, pp. 35-43.