REPUBLIQUE ALGERIENNE DEMOCRATIQUE Et POPULAIRE

MINISTERE DE L'ENSEIGNEMMENT SUPERIEURE Et De La RECHERCHE SCIENTIFIQUE

Université Dr .Yahia Farés de MEDEA

Faculté de la Technologie

Département de Génie Électrique

Mémoire De Fin D'études

Présenté pour l'obtention du Diplôme de Master en Télécommunication

Option : Systèmes Intelligents et Communicants

Thème:

Diagnostic des systèmes physiques : Méthode générique pour la détection des anomalies

Réalisé par :

CHERIET khadidja
DJERIBA samihaMr.

Encadré par :

Mr.SEKKAL Mohammed Chakib

ANNEE UNIVERSITAIRE: 2016/2017

Remerciement

*Je remercie, tout d'abord, **Dieu** tout puissant de m'avoir donné le courage, la force et la patience d'achever ce modeste travail.*

*Je tiens tous d'abord à exprimer ma profonde gratitude à Monsieur «**Sekkal Mohammed Chakib**», Mon encadreur, pour sa présence scientifique et humaine, et l'honneur qu'il m'a fait en acceptant de m'encadrer.*

*Mes remerciements sincères pleins de reconnaissance vont également à Mlle : « **Sihem Abbestorki** », qui m'a soutenue et aidée depuis le début de ce travail.*

*Mes respects et ma gratitude vont également aux membres du **jury** qui m'ont fait l'honneur de juger ce travail et qui par leur disponibilité, leurs observations et leurs rapports m'ont permis d'enrichir mon travail.*

Je remercie toutes les personnes qui ont participé de manière directe ou indirecte à la concrétisation de ce travail.

♥*DJERIBA Samiha* ♥

♥*CHERIET Khadidja*♥

Dédicaces

A la lumière de ma vie, mes très chères parents

Pour leurs amour, leurs prières et leurs sacrifices, pour m'avoir donnée la vie et la joie de vivre. Tes bonne éducation, tes conseils et tes bénédictions n'ont jamais fait défaut, que Allah le tout puissant vous garde pour moi (amin).

A mon frère ***« Taher»*** *et sa femme «* ***Imene****».*

A mon cher frère : ***« Abdellatif »***

A ma adorable sœur « ***Wafaa »*** *qui n'a pas cessé de m'encourager dans les moments difficiles qu'Allah la protège. et son époux et son petit charment «* ***Riadh****»*

A toute la famille ***« DJERIBA»*** *et* ***« YAHIAOUI»***

A mon binôme ***Cheriet Khadidja*** *et sa famille*

A mes collègues Ibtissem,Amel,Nacera,Meriem,Sanaa,Khadidja,Sarra,Kaouther

A touts mes amis.

A toute la promotion 2016-2017.

SAMIHA

Dédicaces

A la mémoire de mon défunt grand-père.

A la lumière de mes yeux mes chers parents qui ont toujours été là pour moi, et m'ont donné un magnifique modèle de labeur et de persévérance, j'espère qu'ils trouveront dans ce travail toute ma reconnaissance et tout mon amoure.

*A mon cher frère : « **Noureddine** » et sa femme et son petit : « **abdelMOUMEN** ».*

*A mon cher frère : « **ALI** » et sa femme et son petit « **IDRISS** ».*

*A ma frangine « **SALIMA** » et son mari et ses petits « **MERIEM** », « **ABD ER_RAOUF** » et « **ZAKARIA** ».*

*A mon cher frère : « **Youcef** »*

A mes tantes et mes oncles et leurs époux et tous cousins et cousines.

*A toute la famille **CHERIET** et **BOUNOUA.***

*A ma binôme « **SAMIHA** » et sa famille.*

*A mes chers amis : « **AMEL** », « **IBTISSEM** », « **FELA** » « **NACERA** », « **SOUHILA** » « **SAMIRA** ». « **kalthoum** » « **amina** »*

A tout mes camarades.

A tous ceux et celles qui me sont chers

KHADIDJA

Résumé

Le diagnostic et / ou le pronostic des systèmes physiques peuvent être obtenus en suivant et en estimant leur état global de santé pendant le fonctionnement. Habituellement, les composantes les plus critiques du système complexe sont surveillées pour déduire leur état de santé et prévoir leurs défaillances futures.

Les composants sont considérés en bon état, jusqu'à la détection d'une défaillance (anomalie) où ils entament une dégradation progressive jusqu'à l'arrêt du système (en panne).

Comme les composants critiques sont hétérogènes, on ne dispose pas d'une méthode générale pour la détection de leurs anomalies. Ceci est un frein à la proposition d'une approche générique de diagnostic de différents systèmes physique.

Le travail réalisé fut de faire un état de l'art des différentes approches de détection d'anomalies qui excitent pour les différents composants critiques, choisir les méthodes qui sont récurrentes (analyse de tendances) puis tester ces méthodes sur différents types de données pour choisir la plus adaptée à une approche de diagnostic générique.

Mots clé :Pronostic, système physique, anomalie ,composant critique ,détection d'anomalie

الملخص

يمكن الحصول على التشخيص و/او تشخيص الانظمة الفيزيائية باتباع وتقدير الحالة الصحية العامة اثناء الوظيفة. عادة المكونات الاكثر اهمية في النظام المعقد تخضع للمراقبة لاستخلاص الحالة الصحية للنظام وبالتالي توقع العطل الذي يعتبر العناصر في حالة جيدة حتى الكشف عن الفشل (شذوذ) حيث يبدأ التدهور التدريجي لإيقاف تشغيل الجهاز(عطل) بما ان العناصر الاساسية غير متجانسة، فانه ليس هناك طريقة عامة للكشف عن الحالات الشاذة هذه المهمة للتطلع على مختلف الطرق والمناهج للكشف عن مختلف العطل التي تثير مختلف العناصر الاساسية.

المطلوب هو اقتراح طريقة عامة لتشخيص مختلف النظم الفيزيائية ويكون بالتطلع عن الحالات الشاذة الخاصة بالعناصر الاساسية واختيار الاساليب المتكررة (تحليل الاتجاهات)ثم اختيار هذه الاساليب على انواع البيانات المختلفة لاختيار اكثر منهج مناسب للتشخيص العام

الكلمات الرئيسية: التشخيص، الانظمة الفزيائية، الشذوذ، العناصر الاساسية، الكشف عن الشذوذ.

Abstract

The diagnosis and / or prognosis of physical systems can be obtained by following and estimating their overall health status during operation. Usually, the most critical components of the complex system are monitored to deduce their state of health and predict future failures.

The components are considered to be in good condition until a malfunction (fault) is detected and progressively degraded until the system is shut down.

Since the critical components are heterogeneous, there is no general method for detecting their anomalies. This is a brake on the proposal of a generic approach to diagnosis of different physical systems.

The work carried out was to make a state of the art of the different approaches of detection of anomalies which excite for the different critical components, to choose the methods which are recurrent (analysis of trends) and then to test these methods on different types of data to choose the most suitable for a generic diagnostic approach.

Keywords: Prognosis, physical system, anomaly, critical component, anomaly detection.

Sommaire

Introduction générale 1

Chapitre I :Maintenance industrielle, diagnostic et pronostic

1. Introduction 4
2. La maintenance industrielle 4
3. Les types de maintenance 5
3.1. La maintenance corrective 6
3.2. La maintenance préventive 7
A. La maintenance préventive systématique 7
B. La maintenance préventive conditionnelle 7
C. La maintenance préventive prévisionnelle 7
4. Prognostic and Health Management (PHM) 8
4.1. Architecture d'un système de PHM 8
4.2. Pronostic et durée de vie résiduelle (RUL) 10
4.3. Détection des défauts dans le PHM 11
4.4. Les approches du PHM 11
A. Pronostic basé sur un modèle physique 12
B. Pronostic guidé par les données 13
C. Pronostic basé sur des approches hybrides 13
5. Méthodes et techniques du PHM guidé par les données 14
5.1. L'analyse temporelle 15
5.2. L'analyse fréquentielle 15
5.3. L'analyse temps- fréquence 15
6. Indicateur de santé et pronostic de system physique 16
7. Détection des anomalies pour la construction d'indicateurs de santé 17
8. Conclusion 17

Chapitre II :Traitement de données et détection des anomalies

1. Introduction 19
2. Evaluation de l'état de santé d'un système industriel 20
3. Traitement de données 20
3.1 Sélection des variables 21
A. L'espérance (Moyenne) mathématique 21
B. La covariance 21
C. La variance 21

D. Coefficient de corrélation 22
E. Sélection des variables par calcul de la matrice de corrélation 22
3.2 Réduction des variables 23
3.3 Extraction des caractéristiques 24
4. Présentation de l'ensemble de données testées 25
4.1 Batterie Li-Ion 25
A. Présentation 25
B. Capteur de Batterie Li-Ion 25
C. Fonctionnement 26
4.2 Les outils de coupes 26
4.3 Les turboréacteurs 27
A. Présentation 27
B. Capteur de turboréacteur 28
C. Le fonctionnement 28
5. Caractéristiques des méthodes de détection 29
6. Les méthodes proposées pour la détection les anomalies 29
6.1 Méthode 01 : Mesure de distance 29
6.2 Méthode 02 : Caractéristiques temporelles 32
6.3 Méthode03 : Clustering 37
6.4 Méthode 04: Transformé de Fourier (FFT) 39
7. Conclusion 40

Chapitre III: Réseaux de Neurones

1. Introduction 41
.2 Historique 41
3. Le Neurone 41
3.1 Le Neurone biologique 42
3.2 Le Neurone artificiel (formel) 42
4. Modélisation d'un neurone formel 43
5. Les critères de choix de réseaux de neurones artificiels 44
5.1. Architecture de réseaux de neurones 44
A. Un réseau de neurones non bouclé 44
B. Réseaux de neurones bouclés 45
5.2 Apprentissage pour un RN 46

A. Définition 46
B. Apprentissage supervisé (avec professeur) 47
C. Apprentissage non supervisé 47
5.3 L'apprentissage de réseau multicouche 47
5.4 Principe de descente de gradient (propagation de gradient) 48
6. Techniques de l'intelligence artificiels 48
7. Domaines d'application des réseaux de neurones (RNA) 48
8. Avantages et Inconvénients des réseaux de neurones 49
8.1 Avantages des réseaux de neurones 49
8.2 Inconvénients des réseaux de neurones 49
.9 Conclusion 49

Chapitre IV:Détection des anomalies par classification neuronale

1. Introduction 50
2. Matlab 50
3. Toolbox NFTOOL de Matlab 50
4. Architecture générale de l'application 51
5.Explication de l'architecture générale de l'application 51
6. Architecture du Réseau de neurone 52
7. Applications 52
7.1 Méthode de distance (p) 54
7.2 Méthode de distance (u) 56
A. La batterie 56
B. Les outils de coupe 58
C. Le turboréacteur 58
7.3 Méthode de Caractéristiques temporelles 59
A. La Batterie 59
B. Les outils de coupes 61
C. Le turboréacteur 63
8. Conclusion 64

Conclusion générale …….66

Liste Des Acronymes

Liste des acronyms

ACP Analyse en Composantes Principales

CBM Condition Based Maintenance

CC Courant constant

Corr Correlation

COV Covariance

CV Tension constante

EIS Spectromètre d'impédance électrochimique

FC Facteur Crête

FFT Transformée de Fourier rapide

Max Maximum **PAC** pile à combustible

PHM Prognostic and Health Management

RMS Root Mean Square

RNA Réseaux de Neurone Artificiel

RUL Remaining Useful Life

STFT Short-Time Fourier Transform

VAR Variance

Liste des figures

Liste des figures

Chapitre I: maintenance industrielle, diagnostic et pronostic

Figure I.1 : Différents types de maintenance …… 6
Figure I.2 : CBM séquentiel architecture …… 9
Figure I.3 : Forme général de RUL …….. 11
Figure I.4 : Classification des approches …….. 12
Figure I.5 : Structure d'un système de pronostic à base d'un modèle physique ….. 13
Figure I.6 : Structure d'un système de pronostic orienté données …….. 13
Figure I.7 : Organigramme de l'approche hybride …….. 14
Figure I .8 : Techniques de traitement du signal (PHM guidé par les données) ….. 15

Chapitre II : Traitement de données et détection des anomalies

Figure II.1 : évaluation de l'état de santé …… 20
Figure II.2 : Exemple de matrice de corrélation …….. 23
Figure II.3 : Techniques d'extraction de caractéristiques……. 24
Figure II.4 : Exemple de batterie Li-Ion ……. 25
Figure II. 5 : les outils de coupe…… 27
Figure II. 6: le turboréacteur …… 27
Figure II.7 : comment fonctionné le turboréacteur ……. 28
Figure II. 8: Le schéma général de méthode globale proposée …… 30
Figure II. 9: mesure de distance Vecteurs Propres (p)…… 31
Figure II. 10: Méthode de distance Valeurs Propres (U) …… 31
Figure II.11: Exemples de caractéristiques temporelles obtenues sur la batterie …. 34
Figure II.12: Exemples de caractéristiques temporelles obtenues sur les outils de coupes…….. 35
Figure II.13: Exemples de caractéristiques temporelles obtenues sur le Tourfan
Figure II. 14: Le schéma général de méthode de clustering …… 38
Figure II. 15 : le dendrograme obtenu à partir du partitionnement sur les distances entre les variables sur les données testés ……... 38
Figure II. 16: FFT obtenue de chaque donnée testée ……... 39

Chapitre III : réseaux de neurones

Figure III.1 : Représentation simplifiée d'un neurone biologique …….. 42
Figure III.2: Le neurone artificiel générique ……... 42
Figure III.3 : Modèle général d'un neurone formel ……. 43
Figure III.4 : Fonctions de sortie des neurones …… 44
Figure III.5 : Réseau de neurone non bouclé …… 45
Figure III.6 : Réseau de neurones bouclé ……. 45
Figure III.7 : Exemple d'apprentissage …… 46
Figure III.8 : Illustration d'apprentissage supervisé ……. 47
Figure III.9 : Illustration d'apprentissage non supervisé …….. 47
Figure III.10: Descente de gradient …….. 48

Chapitre IV : Détection d'anomalies par classification neuronale

Figure IV.1 : Architecture générale de l'application …….. 51
Figure IV.2 : Architecture de Réseau de neurone……..... 51
Figure IV.3 : Affichage de la fenêtre nftool …….. 52
Figure IV.4 : Chargement des entrées et des sorties de programme ……. 52
Figure IV.5 : Chargement des pourcentages ……. 53
Figure IV.6 : Choix du nombre de neurones dans la couche cachée ……. 53
Figure IV.7 : Démarrage de l'apprentissage …….. 53
Figure IV.8: Résultat de l'apprentissage …… 54
Figure IV.9 : Affichage des graphes de performance (MSE) ……. 54
Figure IV.10 : Nommer et sauvegarder le RN …….. 54
Figure IV.11 : Exemple de l'affichage de la sortie "Yd"…….. 55
Figure IV.12: Exemple de l'affichage du "Yr"……. 55
Figure IV.13: Exemple de l'affichage du l'erreur ……. 55
Figure IV.14 : Démarrage de l'apprentissage …….. 56
Figure IV.15 : Résultat de l'apprentissage …… 56
Figure IV.16 : Affichage des graphes de performance (MSE) ……. 57
Figure IV.17: Exemple de l'affichage du "Yr"……... 57
Figure IV.18: Exemple de l'affichage du l'erreur ……. 58
Figure IV.19: v_fact_cret(Batterie)……... 58
Figure IV.20 : Démarrage de l'apprentissage…… 59
Figure IV.21 : Résultat de l'apprentissage……. 59
Figure IV.22: Affichage des graphes de performance (MSE)…….. 60
Figure IV.23: Exemple de l'affichage du "Yr"……. 60
Figure IV.24: Exemple de l'affichage du l'erreur……. 60
Figure IV.25:RMS……. 61
Figure IV.26:Résultat de l'apprentissage……... 61
Figure IV.27: Affichage des graphes de performance (MSE)……... 62
Figure IV.28: Exemple de l'affichage du "Yr"…… 62
Figure IV.29: Exemple de l'affichage du l'erreur…….. 63

Liste des tableaux

Liste des tableaux

Chapitre II

Tableau II. 1 : Variables disponibles pour l'ensemble de données des batteries Li-Ion….25

Tableau II. 2 : Exemples de caractéristiques temporelles……...32

Chapitre IV

Tableau III.1 : résumée le résultat……..64

Introduction générale

Introduction générale

L'efficacité des systèmes industriels est un enjeu économique majeur pour leur exploitation commerciale. Les principales difficultés et sources d'inefficacité résident dans le choix des sessions pour les actions de maintenance. Une action de maintenance consiste à remplacer les équipements du système qui sont en panne et qui ne sont plus capables de réaliser leurs fonctions. Les sessions de maintenance sont coûteuses pour plusieurs raisons et principalement pour l'arrêt du système de production. La décision d'une session de maintenance est très complexe et doit reposer sur une surveillance et une analyse intelligente de l'état de santé du système [1].

La mise en œuvre de ces nouvelles maintenances basées sur l'estimation du temps résiduel avant défaillance d'un équipement (RUL) et la confiance pouvant être associée à cet indicateur, et qui doivent permettre d'éviter des dépenses de maintenance inutiles, requiert une démarche scientifique impliquant différentes tâches telle que la surveillance, la modélisation, l'analyse et l'aide à la décision. Ces tâches font partie du concept appelé PHM : *Prognostics and Health Management* que l'on peut traduire en pronostic et gestion de l'état de santé de systèmes industriels [2].

L'évaluation de l'état de santé des systèmes dans la communauté PHM, est généralement abordée relativement à un niveau équipement, dans notre travail nous nous intéressant aux composants critiques d'un système industriel pour lequel on souhaite surveiller le comportement, suivre l'état de santé et pronostiquer des défaillances.

L'architecture d'un système PHM est généralement formalisée en cohérence avec le standard OSA-CBM (Open System Architecture for Condition Based Maintenance) OSA-CBM comprend six couches parmi lesquelles celle du «*State Detection* ›› qui a pour objectif principal d'analyser l'état de santé actuel de l'équipement surveillé afin de signaler l'apparition d'un fonctionnement anormal. Cette phase requiert par conséquent de disposer au départ d'informations reflétant l'état réel du système puis faire des comparaisons en temps réel et de façon continue [3].mjh

Dans notre travail, on s'intéresse à cette détection d'état ou plus particulièrement à la détection d'anomalies. Par définition, l'anomalie est chaque donnée identifiée en

dehors de la zone de normalité, et la détection des anomalies a pour objectif de détecter le passage du système en fonctionnement anormal.

L'objectif est de transformer les signaux bruts fournis par les capteurs en signaux utiles permettant de détecter le déclenchement d'une dégradation (anomalie). Cette détection est assurée par un Réseau de Neurones (RN) qui classifie les états successifs du composant en état normal ou dégradé.

Les signaux utiles fournis en entrée au RN sont des caractéristiques extraites. Nous avons appliqués différentes méthodes pour dévoiler ces descripteurs. On a appliqué la méthode de caractéristiques temporelles qui est basée sur les descripteurs temporels qui sont les plus faciles à obtenir et à mettre en œuvre. Elles sont efficaces en détection de défaillances. Le calcul de distance entre variables sélectionnées permet de suivre le changement d'état de notre signal obtenu, ainsi détecter un déclenchement d'une dégradation (anomalie). Le *linkage* regroupe les données en classes et permet d'évaluer le seuil pour classé les donnée en deux classes : normal ou dégradé. En fin, la FFT (*Fast Fourier Transforme*) permet de générer le spectre puis après faire des comparaisons entre les piques de fréquences pour détecter l'apparition de l'anomalie, les résultats de chaque méthodes a été détaillée dans les chapitres.

La dite approche doit être générique et fonctionner avec différents types de données. Pour cela, elle a été testée avec trois types de données hétérogènes tous tiré du site de la NASA (*NASA data repository prognosis*) qui sont : Les données sur les batteries Li-ion, les outils de coupe et les turboréacteurs.

En fin, et pour la réalisation de notre système de détection d'anomalies, on a utilisé le logiciel : Matlab.

Notre travail est organisé en trois chapitres répartis comme suit :

Dans le 1^{ier} chapitre :

Présentation de la maintenance industriel, des systèmes industriels, et rappels des architectures de PHM pour la détection des anomalies et la construction des indicateurs de santé.

Dans Le 2^{ièm} chapitre :

Une première partie est consacrée aux rappels sur l'estimation de l'état de santé du système ainsi que la définition de l'ensemble de donnée capteurs pour le traitement de données.

Une seconde partie concerne la présentation de quelques méthodes d'extraction de descripteur pour la détection.

Dans le 3^{ième}chapitre :

La première partie est dédiée à la présentation des généralités sur les RN.

La seconde partie présente les étapes de conception et réalisation de l'application de détection des anomalies. On présente la classification par RN sur les descripteurs extraits par les différentes méthodes testées. L'architecture générale de l'application, les tests, et le tableau final des résultats y sont détaillés.

En fin, une conclusion générale et des perspectives viennent clôturées ce mémoire.

Chapitre I :

Maintenance industrielle, diagnostic et pronostic

1. Introduction

Dans de nombreux secteurs industriels, la disponibilité de l'outil de fabrication et la sûreté de fonctionnement sont des enjeux majeurs pour assurer une continuité optimale de la production. Tout changement indésirable ou un arrêt inattendu provoquera des pertes économiques considérables.

A l'aide des nouvelles technologies, il est possible de mettre en place un système de supervision afin de surveiller les composants du système et de détecter en ligne les problèmes ou les pannes pouvant survenir dans le système. Il est alors possible de fournir un diagnostic et un pronostic de maintenance en ligne. Le premier, analyse les différentes sources d'observation et permet d'identifier les équipements défaillants à remplacer, tandis que le second anticipe un arrêt brutal du système de production.

La maintenance préventive du système industriel, et donc améliorée par l'intégration d'une fonction de pronostic à ce système de supervision. Elle permet de programmer les futures phases de maintenance. Cette fonction de pronostic est souvent basée sur le monitoring de l'état de santé du système industriel, l'estimation de sa dégradation et la construction de son indicateur de santé. Toutes ses étapes sont intiment liées et dépendante de la détection de défauts ou d'anomalie de fonctionnement du système.

2. La maintenance industrielle

Définition

La notion formalisée de maintenance est née dans l'industrie vers la fin des années 1970. Une définition de la maintenance est donnée par la norme AFNOR [4] :

La maintenance est l'ensemble des actions qui permettent de maintenir ou de rétablir un bien dans un état spécifié ou en mesure d'assurer un service déterminé.

Selon cette définition, la maintenance permet de garder un système dans un état préalablement spécifié afin que le système soit capable de fournir les fonctions pour lesquelles il a été conçu. L'analyse des différentes formes de maintenance repose sur trois concepts [1]

- Les événements qui sont à l'origine de l'action de maintenance : référence à un échéancier, résultat de diagnostic, information de capteur, mesure d'usure, apparition d'une défaillance, … etc.
- Les méthodes de maintenance qui leur sont associées : maintenance corrective, maintenance préventive systématique, maintenance préventive conditionnelle, ou maintenance **prévisionnelle**.
- Les opérations de maintenance: inspection, contrôle, dépannage, réparation,… etc.

En fin, Les objectifs de la maintenance peuvent être classés en deux types : [5]

- ***Objectifs financiers:***

- Réduire au minimum les dépenses de maintenance ;
- Assurer le service de maintenance dans les limites d'un budget ;
- Assurer la disponibilité maximale de l'équipement à un prix minimum.

- ***Objectifs opérationnels:***

- Maintenir l'équipement dans les meilleures conditions possibles ;
- Augmenter la durée de vie des équipements ;
- Entretenir les installations avec le minimum d'économie et les remplacer à des périodes prédéterminées ;
- Assurer un fonctionnement sûr et efficace à tout moment.

3. Les types de maintenance

Il existe deux types de maintenance généralement utilisés dans les entreprises : la maintenance corrective et la maintenance préventive. Les différentes catégories de

maintenance en fonction de l'état du système sont illustrées sur la figure I.1 [6] .Chaque type de maintenance et son mode d'application sont détaillés par la suite.

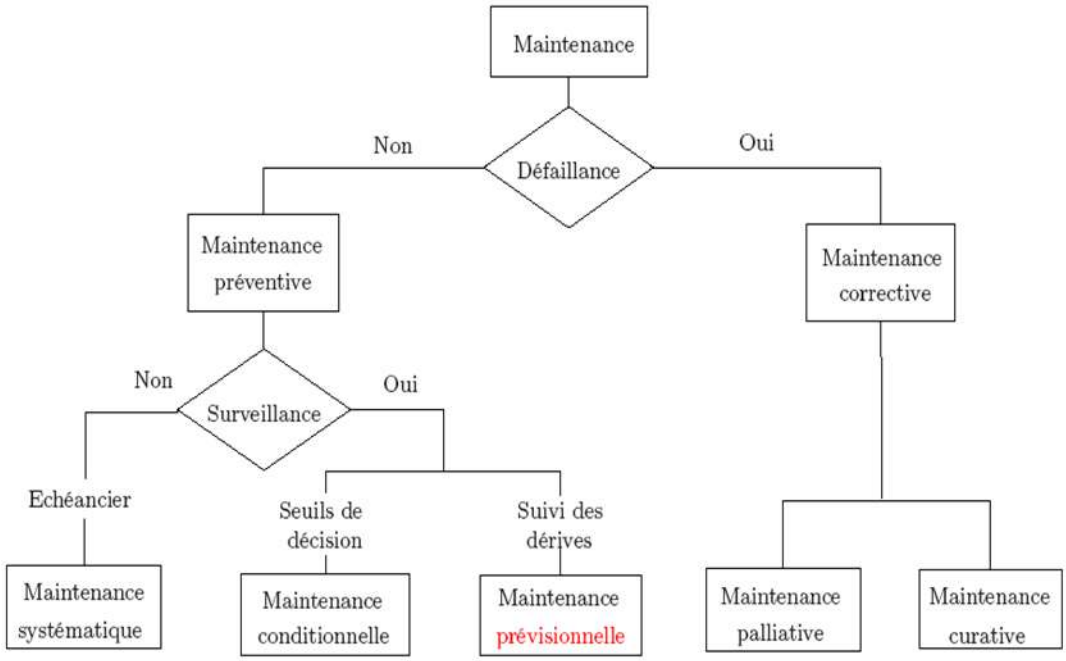


Figure I.1 : Différents types de maintenance

3.1. La maintenance corrective

La maintenance corrective regroupe l'ensemble des activités réalisées après la détection et la localisation d'une défaillance sur un procédé. Elle peut être palliative ou curative. [4]

- La maintenance palliative regroupe les actions permettant à un procédé d'accomplir provisoirement tout ou une partie d'une fonction requise. Elle est appelée couramment le dépannage. Ces actions de maintenance sont principalement constituées d'actions à caractère provisoire qui devront être suivies d'actions curatives.
- La maintenance curative a pour but de rechercher les causes initiales d'une défaillance et de réparer le ou les composant(s) défaillant(s), et ainsi d'éviter toute nouvelle occurrence de défaillance. Le résultat des activités réalisées doit présenter un caractère permanent.

Dans le cas de la maintenance corrective, l'indisponibilité du procédé est maximale et non maîtrisée. La réduction de l'indisponibilité consécutive aux défaillances dépend alors directement de l'efficacité du service de maintenance. Ce service est garant de l'état de fonctionnement du procédé industriel [4].

3.2. La maintenance préventive

La maintenance préventive a pour but d'améliorer la fiabilité et la disponibilité des procédés. Ainsi, elle permet de diminuer le coût de maintenance, notamment en limitant les arrêts de fonctionnement subis. La maintenance préventive comprend trois niveaux : [7]

- La maintenance préventive systématique;
- La maintenance préventive conditionnelle;
- La maintenance préventive prévisionnelle.

A. La maintenance préventive systématique

Consiste en un remplacement périodique des composants du système industriel, selon les préconisations du constructeur, qu'ils soient défectueux ou non. Les inconvénients de cette maintenance périodique résident dans le fait que le composant peut tomber en panne avant l'instant critique prévu par son modèle de défaillance, ou que le composant remplacé aurait encore pu fonctionner longtemps après la date de remplacement.

B. La maintenance préventive conditionnelle

S'appuie sur la mesure et l'analyse de données issues de capteurs. Elle est déclenchée lorsque les paramètres surveillés, caractéristiques des conditions de fonctionnement d'un procédé, dépassent des seuils prédéfinis.

C. La maintenance préventive prévisionnelle

Elle est subordonnée à la surveillance et à l'analyse de l'évolution des paramètres significatifs de la dégradation d'un procédé, autrement dit, l'analyse en temps réel de

l'état de fonctionnement du procédé. On associe souvent la dénomination de maintenance prévisionnelle à celle de maintenance prédictive [8].

Aujourd'hui, la maintenance prévisionnelle tend à s'affirmer comme la solution la plus performante pour répondre aux objectifs de sûreté de fonctionnement et aux contraintes liées à la compétitivité des entreprises. La mise en œuvre de stratégies de maintenance prévisionnelle se justifie par la préoccupation des entreprises à rendre leurs systèmes plus fiables, plus disponibles et plus sûrs. Elle apporte également une meilleure connaissance des défaillances et des dégradations des procédés industriels pendant toute la phase d'exploitation [9].

Note étude s'insère dans ce contexte, car la mise en œuvre d'une stratégie de maintenance prévisionnelle passe nécessairement par la détection de défaillances ou de tous changement dans le comportement nominal du système industriel, appelé communément une anomalie.

4. Prognostic and Health Management (PHM)

Le PHM est une discipline de science de l'ingénieur focalisée sur la détection, la prédiction et le management de l'état de santé des systèmes physiques. Cette discipline est transversale aux domaines de l'instrumentation, du traitement de données et des signaux, de la surveillance des systèmes jusqu'au développement d'un processus d'aide à la décision. L'objectif de cette discipline est d'optimiser le compromis de disponibilité d'un système tout en assurant la sécurité des biens et des personnes par une utilisation de la maintenance industrielle de manière adéquate [10].

Le PHM a pour but d'estimer l'état courant d'un système physique et de prédire sa durée de fonctionnement avant défaillance (communément appelée RUL : Remaining Useful Life) qui a été intégré dans la maintenance préventive conditionnelle.

4.1. Architecture d'un système de PHM

La maintenance préventive conditionnelle se compose d'un certain nombre de modules fonctionnels: acquisition de données, traitement du signal, surveillance, diagnostic, pronostic et l'aide à la décision. En outre, une interface homme-machine peut être ajoutée afin de fournir un moyen d'afficher des informations vitales sur l'état de santé du système [11].

Dans ces travaux, les différences n'apparaissent qu'à un niveau de détail relativement petit, et portent essentiellement sur la forme des architectures logicielles à mettre en œuvre (locale, distribuée, par modules, etc.).Dans l'ensemble, l'architecture proposée par et diffusée par le groupe *MIMOSA* s'avère fédératrice. Il s'agit de la *OSA/CBM* (*Open System Architecture for Condition Based Maintenance*). Cette architecture est schématisée sur la Figure I.2 [12].

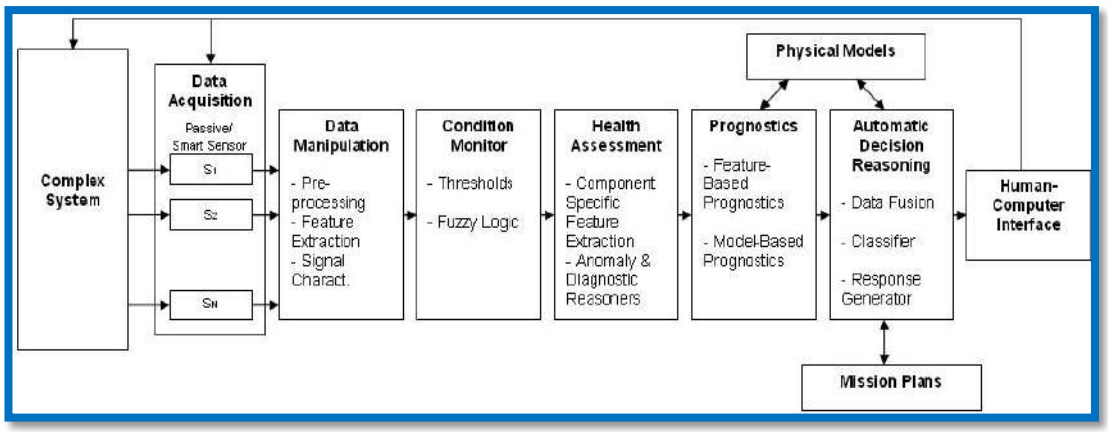


Figure I.2 : CBM séquentiel architecture

Couche 1: Module capteurs. Ce module fournit au système des données numériques issues de capteurs ou de transducteurs

Couche 2: Module traitement du signal. Ce module reçoit les données à partir des capteurs ou transducteurs ou d'autres processeurs de signaux et réalise des transformations de signaux et des extractions de caractéristiques ou de descripteurs.

Couche 3: Module de surveillance. Le module de surveillance compare les données en ligne avec certaines valeurs attendues ou connues ; il doit également être capable de générer des alertes en fonction de seuils préalablement fixés.

Couche 4: Module de diagnostic. Ce module détermine si l'état du système, sous-système ou composant surveillé est dégradé ou non et suggère les défaillances probables.

Couche 5: Module de pronostic. Ce module prédit l'état futur du système, sous-système ou composant surveillé. Le module s'appuie sur les données issues des modules précédents.

Couche 6: Module d'aide à la décision. Sa fonction principale est de recommander des actions de maintenance ou d'autres alternatives pour continuer à faire fonctionner le système jusqu'à l'accomplissement de sa mission.

Couche 7: Module de présentation. Ce module reçoit les informations de tous les modules précédents. Il peut être construit sous forme d'une IHM (Interface Homme-Machine).

4.2. Pronostic et durée de vie résiduelle (RUL)

Le rôle du module de pronostic est de calculer la durée de fonctionnement avant défaillance (communément appelée en anglais RUL : Remaining Useful Life) afin d'anticiper les défaillances sur l'équipement. Cela, par l'estimation de son état de santé actuel et la prédiction de ses états de futurs [13].

La durée de vie résiduelle d'un système correspond au temps restant avant que le système ne soit plus capable de remplir les fonctions pour lesquelles il a été conçu. Dans ce cas, le processus de pronostic peut être défini comme un processus dont l'objectif est de prévoir le temps restant avant la défaillance à partir de l'instant courant et selon l'historique de fonctionnement [13].

Le RUL est une prédiction à la notion de temps. Il est défini à partir de l'instant de détection d'un défaut (une anomalie) t_c sur l'horizon de temps, jusqu'à l'apparition de la défaillance à l'instant *T*. Cette métrique est illustrée au travers la figure I.3 [11].

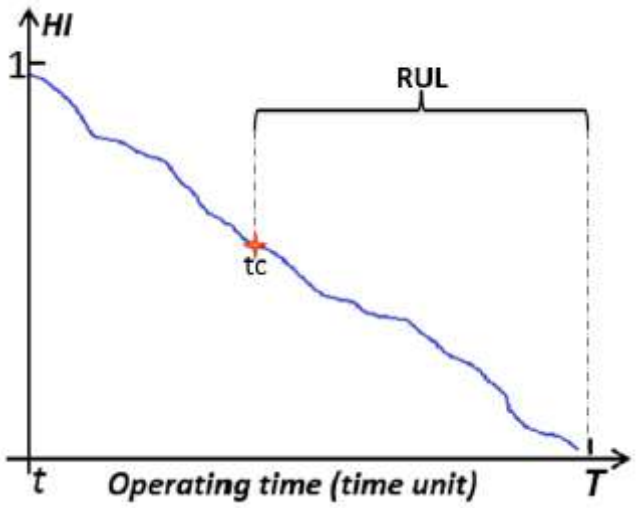


Figure I.3 : Forme général de RUL.

4.3. Détection des défauts dans le PHM

La détection des défauts consiste à déterminer si une erreur s'est produite dans le système de surveillance. [14]

Dans nos travaux de recherche nous nous sommes focalisés sur le pronostic de défaillances, avec comme modules supports l'acquisition et le traitement de données. Ce choix est principalement motivé par le fait que la détection et le diagnostic de défaillances, qui sont en amont du pronostic, sont des activités matures et bien développées aussi bien au niveau scientifique qu'au niveau industriel

Comparé au diagnostic, qui intervient a posteriori suite à une défaillance pour rechercher les causes, le pronostic a pour but d'anticiper la défaillance et permet ainsi à l'exploitant de ne pas subir les conséquences des défaillances, d'augmenter la disponibilité de ses systèmes, d'améliorer leur sécurité et de réduire les coûts de maintenance, car les interventions ne sont pas réalisées dans l'urgence.[3]

4.4. Les approches du PHM

Le PHM peut être réalisée selon trois principales approches [12] :

- L'approche basée sur un modèle physique ;
- L'approche guidée par les données ;
- l'approche hybride combinant les deux approches précédentes.

La figure I.4 résume les diverses méthodes de pronostic qui peuvent être appliquées à différents systèmes et les coûts relatifs à leur exploitation et mise en œuvre.

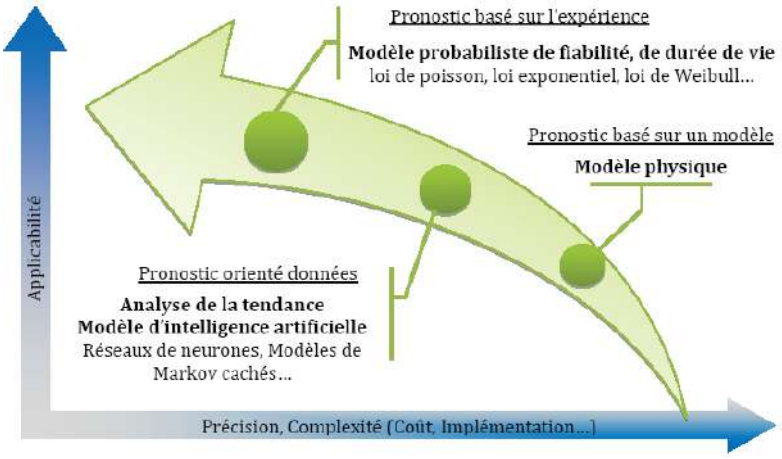


Figure I.4 : Classification des approches

A. Pronostic basé sur un modèle physique

Le pronostic basé sur un modèle physique utilise des représentations mathématiques pour intégrer une compréhension physique du processus de dégradation du système. Un schéma conceptuel du pronostic basé sur un modèle physique est représenté sur la figure I.5 Des fonctions mathématiques, comme les équations différentielles sont développées pour représenter le système. Ces équations sont ensuite utilisées dans des techniques d'estimations statistiques telles que les filtres de Kalman et les relations de parité dans le but d'estimer l'état du système [13].

Les résidus qui sont la différence entre les prédictions du modèle et les observations du système sont ensuite utilisés pour détecter, isoler et prédire la dégradation du système. Les résidus montrent la divergence entre le modèle du système et les observations réelles. L`analyse statistique des résidus est utilisée pour quantifier la dégradation dans le système suivant laquelle la prédiction est réalisée

afin d'estime le temps restant avant l'apparition d'un défaut en fixant un seuil de défaut prédéfini. [13]

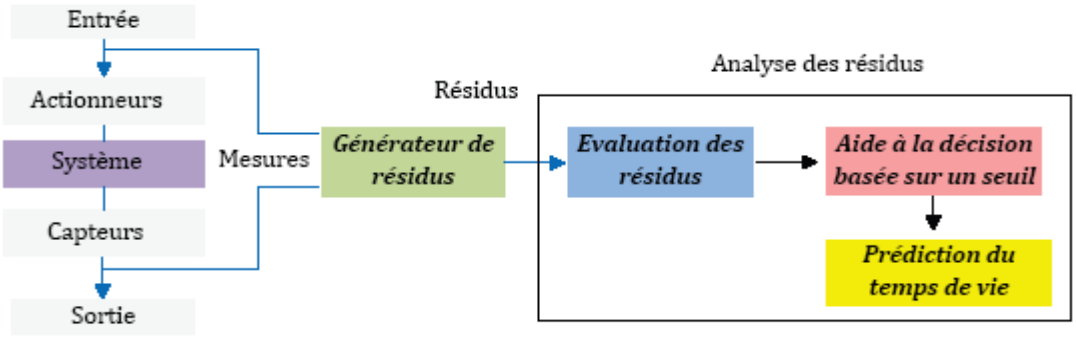


Figure I.5 : Structure d'un système de pronostic à base d'un modèle physique

B. Pronostic guidé par les données

Le pronostic guidé par les données se base sur l'hypothèse que les données de surveillance d'un système restent relativement inchangées jusqu'à l'apparition d'un défaut. Dans cette approche, la surveillance du système est effectuée à l'aide de paramètres de surveillance qui indiquent la dégradation du système. Les données recueillies sont d'abord analysées pour détecter d'éventuelles anomalies. Ensuite, l'évolution de la tendance des paramètres de surveillance est utilisée pour estimer le temps restant avant la défaillance du système en utilisant des algorithmes de prédiction. L'organigramme présenté sur la figure I.6 résume les étapes de la mise en œuvre d'un pronostic guidé par les données. [13].

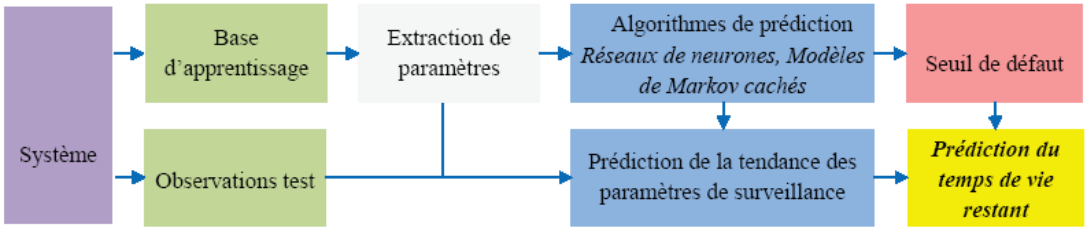


Figure I.6 : Structure d'un système de pronostic orienté données

C. Pronostic basé sur des approches hybrides

Les approches hybrides combinent les avantages de deux approches précédentes, ils utilisent la connaissance sur le comportement physique du système et l'information obtenue à partir d'une analyse pertinente des données de surveillance.

La combinaison de ces approches offre un moyen pour corréler les tendances des données et des événements précurseurs par lesquels se manifeste un mécanisme de dégradation, contribuant ainsi à isoler la cause de défaillance.

Le diagramme de l'approche hybride pour le PHM est illustré sur la Figure I.7 L'approche présentée ici permet l'utilisation de l'information extraite de deux approches précédentes capables de détecter et isoler les paramètres contributeurs de défaillances. Les paramètres critiques qui y étaient identifiés sont utilisés dans les modèles physiques pour fournir des informations exactes selon le degré du dommage, et de ce fait, établir un moyen efficace pour calculer le RUL du système. [15].

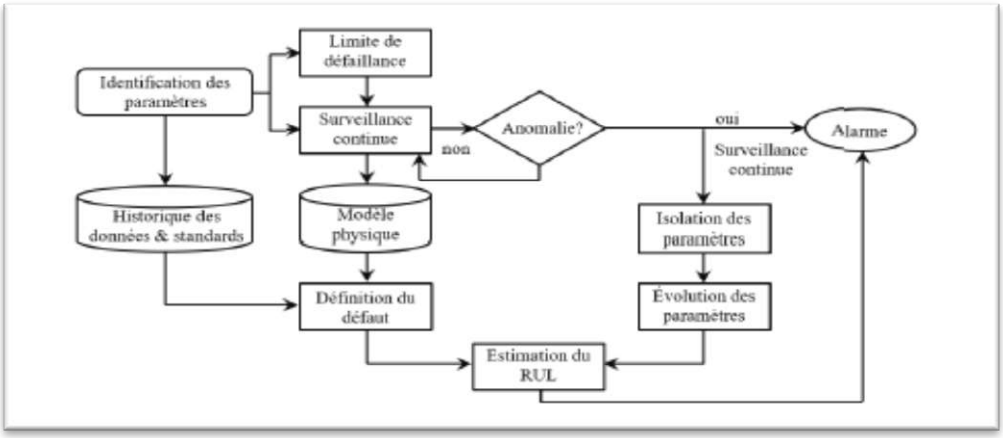


Figure I.7 : Organigramme de l'approche hybride [15]

5. Méthodes et techniques du PHM guidé par les données

Le traitement des données et signaux fournis par les capteurs dans le PHM guidé par les données a pour finalité d'extraire des caractéristiques pertinentes permettant de construire un indicateur de santé pouvant nous renseigner sur l'état de santé à tout instant de l'équipement surveillé.

Les caractéristiques extraites peuvent être temporelles, fréquentielles ou un mélange des deux Comme le montre la figure 1.8 Il est donc possible de classer les techniques de ce traitement du signal en : Analyse temporelle, Analyse fréquentielle et Analyse temps-fréquence.

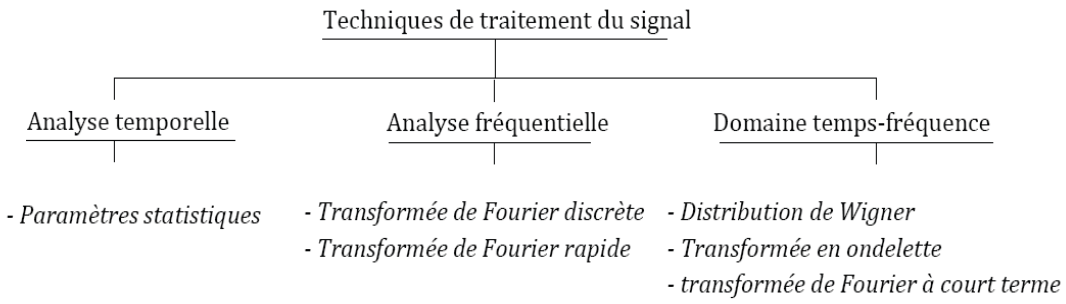


Figure I .8 : Techniques de traitement du signal (PHM guidé par les données) [15]

5.1. L'analyse temporelle

L`analyse temporelle permet d'extraire des paramètres indicateurs de défauts à partir de données brutes du capteur. Les paramètres décrits ici sont appelés paramètres statistiques car ils sont basés sur une analyse des caractéristiques temporelles statistiques du signal enregistré [15].

5.2. L'analyse fréquentielle

L'analyse du spectre fréquentiel d'un signal est la technique la plus couramment utilisée pour identifier les défauts dans un système. Cette technique est basée sur le fait qu'un défaut localisé génère un signal périodique avec une fréquence caractéristique unique [16]. Parmi les techniques utilisées dans le domaine fréquentiel est l'analyse spectrale par transformée de Fourier rapide FFT *(*Fast Fourier Transform).

5.3. L'analyse temps- fréquence

L'analyse en temps-fréquence des signaux traite à la fois le domaine temporel et le domaine fréquentiel. Les signaux capteur qui sont non stationnaires sont mieux représentés par une distribution temps-fréquence, qui vise à montrer la répartition de l'énergie du signal sur l'espace à deux dimensions temps-fréquence [17]. Les techniques les plus utilisées pour l'analyse temps-fréquence sont la transformée de Fourier à court terme (STFT) pour Short-Time Fourier Transform, la distribution de Wigner-Ville et la transformée en ondelettes [18].

6. Indicateur de santé et pronostic de system physique

Un indicateur est défini comme une mesure objective qui reflète un résultat ou un état. Il permet de suivre les changements et les évolutions d'une information quelconque représentant ce résultat/état [19]. En lien avec la notion de santé. Un indicateur est exprimé en un seul nombre, délivrant une information sur l'état physique d'un système ou encore reflétant les objectifs et les moyens pour un processus. Il est issu de la transformation des données relatives aux caractéristiques à évaluer afin d'en extraire une quantification facilement interprétable par l'utilisateur [7].

L'indicateur est alors le principal moyen pour exprimer l'information sur la santé des systèmes physiques ainsi permet de détecter un comportement anormal pendant le fonctionnement d'un système et à mesurer l'étendue de la déviation d'une ou plusieurs caractéristiques d'un fonctionnement nominal [20].

Plus précisément, un indicateur de défaillance est une quantité significative et pertinente à partir de laquelle il est possible de détecter une défaillance ou une dégradation. [21]

Ce qui est nécessaire dans les indicateurs de santé, c'est l'information liée au début et à l'évolution de la dégradation, éventuellement cachée dans la surveillance d'une quantité énorme de données brutes.

En général; Les techniques de traitement des signaux de données sont nécessaires grâce à l'extraction des caractéristiques, à la réduction et à la sélection des variables, puis à la construction des indicateurs de santé. Ce sont des processus très difficiles qui doivent traiter en même temps avec la nature (spécifique au composant, bruyant, très grand et manquant, multi-variabilité, non stationnaire) des données du signal et les caractéristiques souhaitées de la monotonie, de la tendance et de la pronosticabilitée pour Les indicateurs [22].

7. Détection des anomalies pour la construction d'indicateurs de santé

Le principe de base pour détecter une anomalie repose sur la définition d'une zone de normalité de fonctionnement. Chaque donnée identifiée en dehors de cette zone de normalité est alors considérée comme une anomalie. En pratique, il faut donc définir cette région de normalité et séparer les données « normales » des données « anormales ». Cette séparation est rendue complexe par le fait que toutes les mesures sont entachées de bruit [22].

La détection des anomalies a pour objectif de détecter le passage du système en fonctionnement anormal. Les données issues des capteurs sont transformées en des indicateurs de santé permettant de classer les situations observées comme étant normales ou anormales.

Pour ce domaine, les méthodes de détection sont confondues avec les outils de surveillance d'une manière générale. En effet, la détection est la première fonction dans un processus de surveillance formé par les deux fonctions de détection et de diagnostic. Cette dernière consiste à localiser les anomalies une fois détectées et à identifier leurs causes [13]

8. Conclusion

La surveillance et l'évaluation de l'état de santé des systèmes physiques est intégré dans l'architecture CBM telle quelle est présentée dans ce chapitre. L'anticipation des défaillances nécessaire pour une stratégie de maintenance prévisionnelle ne peut se faire que si les phénomènes de dégradation sont correctement appréhendés (acquisition de données, extraction de descripteurs, détection/surveillance, diagnostic, génération d'indicateur de santé et pronostic).

Dans ce chapitre, nous avons montré qu'un pronostic guidé par les données ne peut être fiable que si l'indicateur de santé sur lequel il repose soit représentatif de la

dégradation. Pour cela la détection de défauts ou d'anomalies est plus que nécessaire dans la construction d'un bon indicateur de santé car elle marque en générale le début de la dégradation.

Dans le chapitre suivant, nous présentons l'ensemble de données que nous avons testées ainsi nous avons abordé la problématique globale du traitement des données de surveillance pour extraire les informations et appliquer des méthodes de détection pour construire des indicateurs permettant de suivre l'état de santé de composants critiques

Chapitre I I:

Traitement de données et détection des anomalies

1. Introduction

L'évaluation de la santé des systèmes industriels est souvent diffuse dans les travaux de PHM. En effet, la santé est réduite à des alertes de dégradation (résultat de la fonction de détection des anomalies) ou encore renvoyée directement à un résultat de diagnostic sans de réelles explications sur la tendance de déviation par rapport à la normalité , En outre, la description de la santé d'un équipement est souvent liée à un domaine particulier ou encore à une technique relative à la nature des données mesurées[23].

Le travail que nous somme en cours de présenter dans ce rapport s'inscrit dans le cadre de la réalisation d'une technique PHM entièrement orienté vers le suivi de l'état de santé d'un système industriel. Cette technique fait abstraction du mode de fonctionnement de ce système ainsi que de la nature des données mesurées. De ce fait, la détection d'anomalies qui en est le premier pivot est soumise aux mêmes conditions. D'où ce besoin de faire une étude sur différentes méthodes de traitement de données appliquées à différents types de mesures.

Ainsi ,les méthodes de détection de défaillances et de dégradations utilisées dans les différents secteurs industriels sont très variées et tiennent compte de la spécificité des matériels qui constituent leurs procédés. De plus, la grande diversité des technologies des systèmes industriels (mécanique, thermique, électrique, électronique, numérique...) ne permet pas d'utiliser une méthode universelle qui posséderait tous les avantages et aucun inconvénient.

Nous présentons dans la suite, un ensemble de méthodes de détection qu'on testera sur les données présentées ci-dessus. L'objectif est de trouver la catégorie des méthodes de détection qui nous intéresse pour notre étude parmi les différentes méthodes de détection de la littérature.

2. Evaluation de l'état de santé d'un système industriel

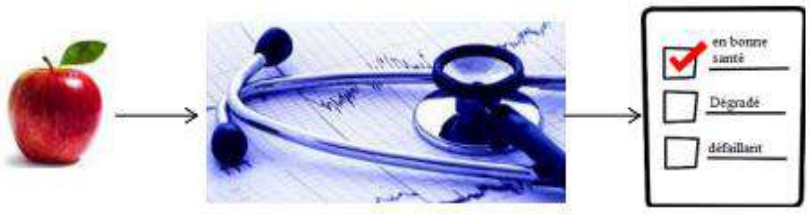


Figure II.1 : évaluation de l'état de santé

L'évaluation de l'état de santé d'un système est appréhendé dans la littérature scientifique, comme un problème de classification de données capteurs. Les différents états correspondent chacun a un mode de fonctionnement de l'équipement (comme mode Normal, dégradé de type 1, dégradé de type 2 jusqu'au mode défaillant). Dans ce cadre, différents algorithmes de détection des anomalies ont été appliqués [3].

Les algorithmes de détection d'anomalies sont appliqués sur des données collectées sur les composants critiques des systèmes industriels. Un **composant critique** est un composant qui présente un taux de défaillance élevé et/ou dont la défaillance entraîne l'indisponibilité du système dans lequel il est utilisé. Un ou plusieurs composants critiques peuvent exister dans un même système [14]

Les données acquises à partir du composant surveillé ne peuvent pas être utilisées directement pour la détection en raison de leur redondance et de leur grande dimensionnalité. Différentes techniques d'analyse de données sont alors utilisées pour découvrir des informations utiles sur le processus de dégradation. [3]

3. Traitement de données

Le traitement se fait sur des données de surveillance fournies par les capteurs installés sur les composants critiques du système industriel. Il est donc nécessaire de les traiter ces données pour révéler leur contenu et permettre de détecter à tout instant tout changement d'état du composant critique susceptible d'être une anomalie.[24]

3.1 Sélection des variables

Le but de cette étape est de sélectionner un sous-ensemble optimal de variables en fonction de certains critères de performance. Une méthode simple utilisée pour la sélection des variables est la matrice de corrélation. Ses éléments mesurent le degré d'association linéaire entre des variables aléatoires [25].

Cette partie présente la méthode de sélection des variables utilisée qui est basée sur le calcul de la matrice de corrélation.

D'abord, on va citer quelques définitions sur les notions de base statistique concernant la corrélation.

A. L'espérance (Moyenne) mathématique

C'est la moyenne pondérée par la probabilité, de toutes les valeurs des événements de l'espace échantillonné. Pour la calculer, on fait le produit de la valeur de chaque résultat possible par sa probabilité d'apparition et on fait la somme de tous les produits ainsi obtenus [26].

$$E(x) = \sum x_i \cdot P(x_i) = \sum x_i \cdot p_i \qquad \textbf{(II.1)}$$

B. La covariance

C'est une mesure de la force du lien entre deux variables aléatoires (numériques). Elle est définie par:

$$Cov(X_1, X_2) = E(X_1, X_2) - E(X_2)E(X_1) = E\left[(X_1 - E(X_1)) \cdot (X_2 - E(X_2))\right] \qquad \textbf{(II.2)}$$

L'inconvénient de la covariance est que sa valeur dépend des unités dans lesquelles sont exprimées les variables $X1$ et $X2$, alors qu'une mesure de la force du lien entre deux variables ne devrait certainement pas en dépendre.

On note aussi que $Cov(X, X) = Var\left[X\right]$ c'est-à-dire la covariance d'une variable avec elle-même est égale à la variance [26].

C. La variance

C'est le carré moyen de l'écart entre X et sa moyenne [26].

$$Var(X) = E\left[(X - E(X)^2\right] \qquad \textbf{(II.3)}$$

.

D. Coefficient de corrélation

Le coefficient de corrélation est défini alors comme suit:

$$\rho = \frac{Cov(X,Y)}{\sqrt{Var(X).Var(Y)}} \quad \textbf{(II.4)}$$

La corrélation est une mesure du degré d'association entre deux variables aléatoires X et Y. Plus précisément, nous devrons parler d'association linéaire, parce que nous avons dès le départ utilisé des prédicateurs linéaires en X et en Y [26].

- **Propriétés:**
  - Les valeurs extrêmes **ρ** = 1 ne sont atteintes que lorsque la relation entre X et Y est parfaitement linéaire.
  - Notons également que, puisque la covariance entre des variables indépendantes est nulle, nous pouvons conclure que, si X, Y sont indépendantes, leurs corrélation est nulle.
  - Aussi nous disons qu'il y a une relation moyennement linéaire entre X, Y si la valeur de corrélation est entre 0.3 et 0.5.
  - Si la valeur est supérieure à 0.5 alors il y a une relation frottement linéaire.
  - Sinon, si la corrélation est inférieure à 0.3 alors X, Y ne sont pas corrélés.

E. Sélection des variables par calcul de la matrice de corrélation

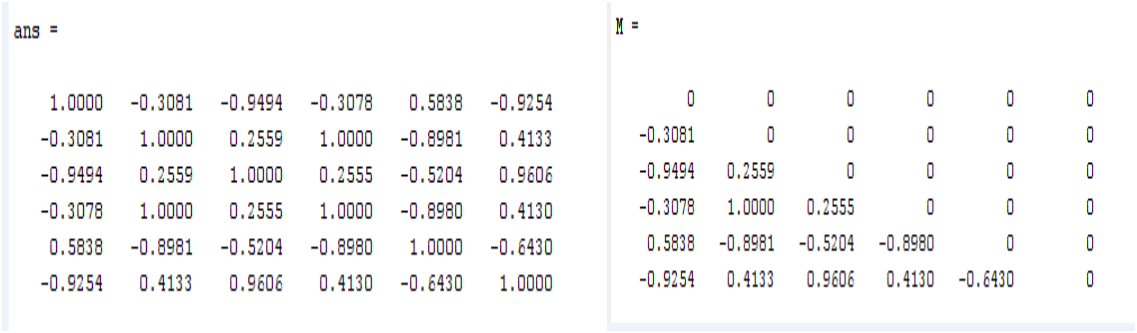
La matrice de corrélation est tout simplement la matrice des coefficients de corrélation calculés sur plusieurs variables prises deux à deux. La figure II.2 en donne un exemple.

La valeur 1 signifie que les deux variables sont exactement corrélées, c'est le cas d'une relation exactement linéaire entre deux variables

La moitié marquante de la matrice peut être complétée par une symétrie selon la diagonale si les corrélations sont réversibles

Si on a assez de données, on peut considérer qu'une corrélation supérieure à 0.80

Une corrélation significative indique une liaison entre deux variable, mais pas nécessairement un lien de causalité.



ans =

1.0000	-0.3081	-0.9494	-0.3078	0.5838	-0.9254
-0.3081	1.0000	0.2559	1.0000	-0.8981	0.4133
-0.9494	0.2559	1.0000	0.2555	-0.5204	0.9606
-0.3078	1.0000	0.2555	1.0000	-0.8980	0.4130
0.5838	-0.8981	-0.5204	-0.8980	1.0000	-0.6430
-0.9254	0.4133	0.9606	0.4130	-0.6430	1.0000

M =

0	0	0	0	0	0
-0.3081	0	0	0	0	0
-0.9494	0.2559	0	0	0	0
-0.3078	1.0000	0.2555	0	0	0
0.5838	-0.8981	-0.5204	-0.8980	0	0
-0.9254	0.4133	0.9606	0.4130	-0.6430	0

Figure II.2: Exemple de matrice de corrélation

3.2 Réduction des variables

Pour mieux visualiser et suivre la forme des variables, on les projette dans un espace de dimension réduite (généralement deux ou trois dimensions).Dans notre cas, en utilisant une méthode de réduction linéaires qui est l'Analyse en Composantes Principales (APC), on ramène la dimension de notre espace de variable à 1.

L'ACP est une méthode de réduction linéaire utilisée pour la réduction et la visualisation de données ainsi que pour l'extraction de caractéristiques [26]. Elle consiste à projeter les données à réduire dans un espace linéaire, de dimension plus petite, formé par les composantes principales de telle sorte que la variance des données projetées soit maximale.

Soit X une matrice de données de dimension M*N, où M représente le nombre d'observations et N les vecteurs de caractéristiques. On notera x1; x2;…;x_n les vecteurs colonnes de la matrice X. Les étapes utilisées pour la réalisation d'une ACP sont résumées ci-dessous

1. Calculer la moyenne μ_i, i = 1,…, N. de chaque vectrice colonne.

2. Centrer les colonnes en soustrayant la moyenne de convecteur correspondant :

$$xi - \mu_i,\ i = 1,\ldots, N.$$

3. Calculer la matrice de covariance S de la matrice X centrées. La matrice de covariance est de dimension N*N.

4. Calculer les valeurs propres λi, i = 1,…, N ainsi que les vecteurs propres Vi, i = 1,..., N de la matrice de covariance obtenue.

5. Ordonner les valeurs propres obtenues dans l'ordre décroissant (de la plus grande valeur à la plus petite valeur).

6. Garder les p vecteurs propres correspondant aux p plus grandes valeurs propres de telle sorte que la variance désirée à capturer soit égale ou supérieure à$\frac{\sum_{i=1}^{p} \lambda i}{\sum_{i=1}^{N} \lambda i}$. Dans la pratique,

La valeur minimale de variance retenue est de 75 %.

7. Normaliser les vecteurs propres retenus pour que leur norme soit égale à 1. Les vecteurs normés obtenus $\mu i = \frac{1}{\sqrt{N\lambda i}}$vi, i=1, …p représentent les directions principales et forment le nouvel espace dans lequel les données sont projetées (nouvel espace de représentation) pour obtenir les composantes principales.

3.3 Extraction des caractéristiques

Dans le cas du PHM, l'extraction de caractéristiques repose essentiellement sur des techniques issues du traitement du signal. Ces techniques peuvent être regroupées dans deux catégories principales selon que le signal à traiter est stationnaire ou non stationnaire Les signaux stationnaires sont caractérisés par des propriétés statistiques invariantes dans le temps. Pour ces signaux, on distingue deux groupes de techniques : le premier groupe génère des caractéristiques temporelles et le second groupe des caractéristiques fréquentielles. Concernant les signaux non stationnaires, ils sont caractérisés par des propriétés statistiques dépendantes du temps. Dans cette catégorie, les aspects temporel et fréquentiel sont tous les deux pris en compte lors de la génération de caractéristiques. La figure II.4 donne un aperçu des techniques utilisées pour l'extraction de caractéristiques [3].

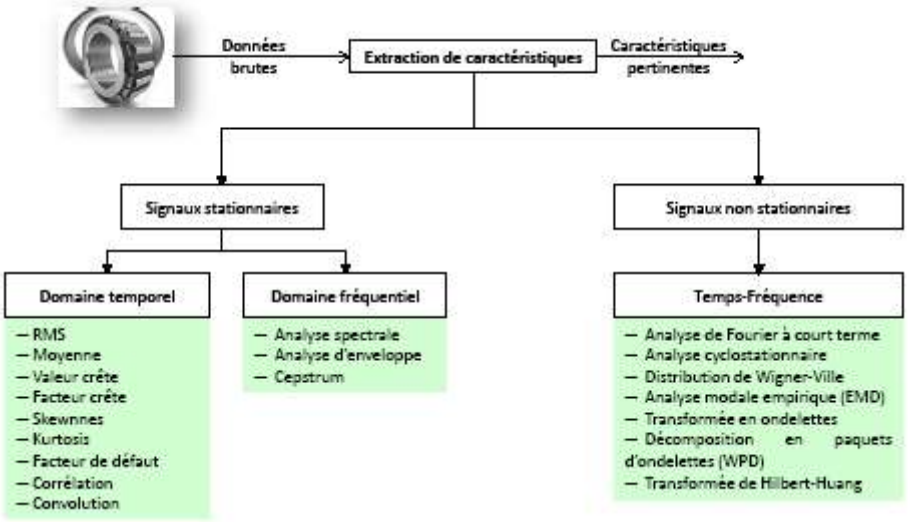


Figure II.3 : Techniques d'extraction de caractéristiques

4. Présentation de l'ensemble de données testées

Nous utilisons dans nos travaux des données de référence qui sont tirées du « NASA data repository prognosis»[27].

4.1 Batterie Li-Ion

A. Présentation

Une batterie Li-Ion est composée de plusieurs cellules connectées en série et en parallèle en fonction de la tension et des exigences de l'appareil. Trois types différents de cellules de batterie Li-Ion sont couramment utilisés : cylindrique, prismatique et polymère; utilisés dans les ordinateurs portables, les tablettes et téléphones.[27].



Figure II.4: Exemple de batterie Li-Ion

B. Capteur de Batterie Li-Ion

Un capteur de batterie contrôle permanence l'état de la batterie.il est très compact et le plus souvent placé directement sur la borne négative de la batterie.

Le capteur comporte généralement :

- une connexion entre la borne négative de la batterie et le châssis.
- une connexion entre la borne B+ de l'alternateur.
- une connexion avec le calculateur pour le transfert d'informations sous de bus de données.

le capteur de batterie permet de reconnaitre l'état de charge, l'état de décharge et la capacité restante et l'état de vieillissement de la batterie. [28].

C. Fonctionnement

La batterie Li-ion a été parcourue par 3 profils opérationnels différents (charge, décharge et impédance) à température ambiante.

La charge a été effectuée en mode courant constant (CC) à 1.5A jusqu'à ce que la tension de la batterie atteigne 4.2V puis continue en mode de tension constante (CV) jusqu'à ce que le courant de charge baisse à 20mA. La décharge a été effectuée à un niveau de courant constant (CC) de 2A jusqu'à ce que la tension de la batterie tombe à 2.7V. La mesure de l'impédance a été réalisée à l'aide d'un spectromètre d'impédance électrochimique (EIS) de 0,1 Hz à 5 kHz. Les cycles de charge et de décharge répétés entraînent un vieillissement accéléré des batteries, tandis que les mesures d'impédance donnent un aperçu des paramètres internes de la batterie qui changent à mesure que le vieillissement progresse. Les expériences ont été arrêtées lorsque les batteries ont atteint les critères de fin de vie (EOL), qui était une capacité nominale de fondu de 30% (de 2 heures à 1,4 heures). Cet ensemble de données peut être utilisé pour la prédiction de la charge restante (pour un cycle de décharge donné) et de la durée de vie utile restante (RUL). [27]

Ce tableau illustre les différents champs de chaque profil :

Tableau II. 1 : Variables disponibles pour l'ensemble de données des batteries Li-Ion

	Charge \ Discharge	Impedance
1	Voltage measured (Volts)	Sense current (Amps)
2	Current measured (Amps)	Battery current (Amps)
3	Temperature measured (C°)	Current ratio
4	Current load (Amps)	Battery impedance (Ohms)
5	Voltage load (Amps)	Rectified impedance (Ohms)
6	Time (Secs)	/

4.2 Les outils de coupes

L'outil de coupe est l'élément qui enlève la matrice. Il existe une très grande variété d'outils de coupe : différents types de géométries, de matériaux et de revêtements. Dans ces travaux. Une configuration d'outil simple sera développée. La partie active de l'outil fera l'objet d'une description voir la figure II.5 géométrique simple, sans brise copeau sur la face de coupe, sans préparation d'arête particulière. Un outil de coupe de tournage peut

être caractérisé par une géométrie d'arête et une orientation dans l'espace définie par des angles de coupe normalisés. [28]

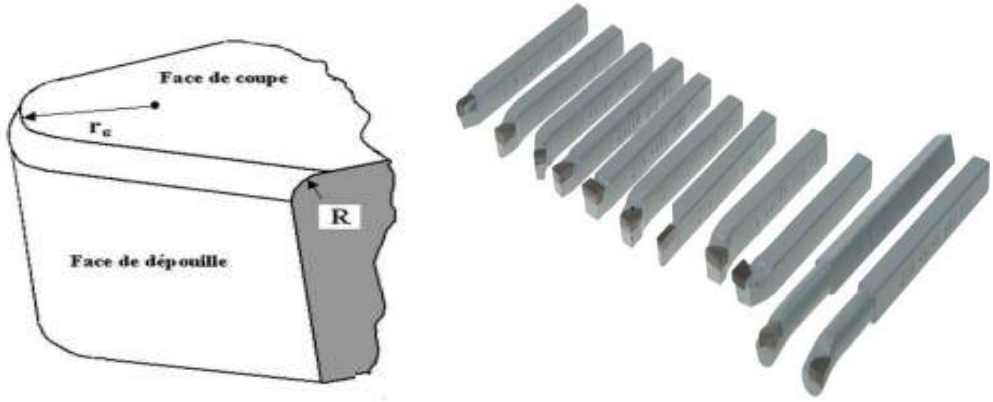


Figure II.5 : les outils de coupe

4.3 Les turboréacteurs

A. Présentation

C'est un système de propulsion qui transforme l'énergie potentielle contenue dans un carburant, associé à l'air ambiant, en énergie cinétique permettant de générer une force de réaction en milieu élastique dans le sens opposé à l'éjection. La poussée générée résulte de l'accélération d'une certaine quantité d'air entre l'entrée (buse d'entrée d'air) et la sortie (tuyère d'éjection). [29]

Afin d'injecter une quantité d'air suffisante en masse, un accroissement de la pression à vitesse à peu près constante est assuré par le compresseur d'entrée



Figure II.6: le turboréacteur

B. Capteur de turboréacteur

Sur chaque moteur d'avion, des capteurs sont placés à différents endroits a fin de recueillir, tout au long du vol, des informations sur le contexte extérieur (température extérieure, pression extérieure, ...) et sur l'état du moteur (vitesse de rotation, pression d'huile, EGT...). Ces informations sont indispensables pour le pilote qui doit assurer le bon déroulement du vol. Ces informations sont également utilisées par le système de régulation qui transforme la position de la manette en une commande qui est envoyée au moteur et qui est compatible avec la sécurité du vol. [30].

C. Le fonctionnement

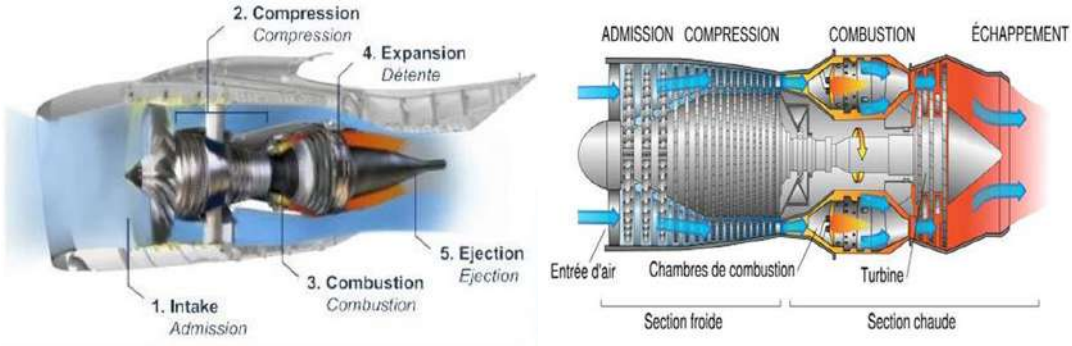


Figure II.7: comment fonctionné le turboréacteur

1- **l'admission** :l'air passe par la soufflante, la rotation des aubes de celle-ci provoque une accélération de l'air qui se propage dans le compresseur par le flux primaire, autour par le flux secondaire.

2- **la compression** : le compresseur aspire l'air provenant de la soufflante (flux primaire) et le compresse de manière à atteindre les meilleures conditions possibles de pression et de températures.

3- **la combustion** : l'air provenant du compresseur dans la chambre de combustion. Il est alors fortement chauffé par du kérosène enflammé, il en résulte que l'air se dilate et est éjecté dans la turbine.

4- **la détente** : la turbine prélève une partie de l'énergie de l'air dilaté sorti de la chambre de combustion, afin de provoquer la rotation du compresseur et de la soufflante via l'arbre de la turbine.

5- **l'éjection** : à la sortie de la turbine, l'air va poursuivre sa détente dans la tuyère. Cet air issu du flux primaire, est mélangé avec l'air va secondaire pour produire la poussée. [31]

5. Caractéristiques des méthodes de détection

Il existe un grand nombre de méthodes de détection. Ces méthodes se basent sur un modèle du comportement normal et/ou défaillant du système.

L'observation réelle de l'état courant du système, sujet du diagnostic et la détection, est comparée avec l'état estimé par le modèle afin de détecter un défaut. Chacune des méthodes de détection doit garantir les caractéristiques suivantes :

- Le diagnostic et la détection doit être facile à implémenter,
- Le nombre de capteurs (des variables) nécessaire pour le diagnostic doit être minimal,
- Le diagnostic et la détection doit être prédictif,
- Le diagnostic doit être réalisable en temps réel, [32]

6. Les méthodes proposées pour la détection les anomalies

Notre démarche s'est intéressée à identifier l'instant de basculement de l'état de santé courant d'un composant critique d'un système industriel vers le premier état dégradé.

Le suivi en ligne est fait par la modélisation des données capteurs en descripteurs (features) extrait dans différents domaines qui permettent de classifier l'état courant en classe de bonne santé ou celle d'état dégradé. Les méthodes testées sont détaillées ci-dessous.

6.1 Méthode 01 : Mesure de distance

Nous avons écrit un programme sous MATLAB qui fonctionne avec des données capteurs. Le démarche de cette méthode a été illustre dans le schéma de la figure II.8 et détaillé par la suite :

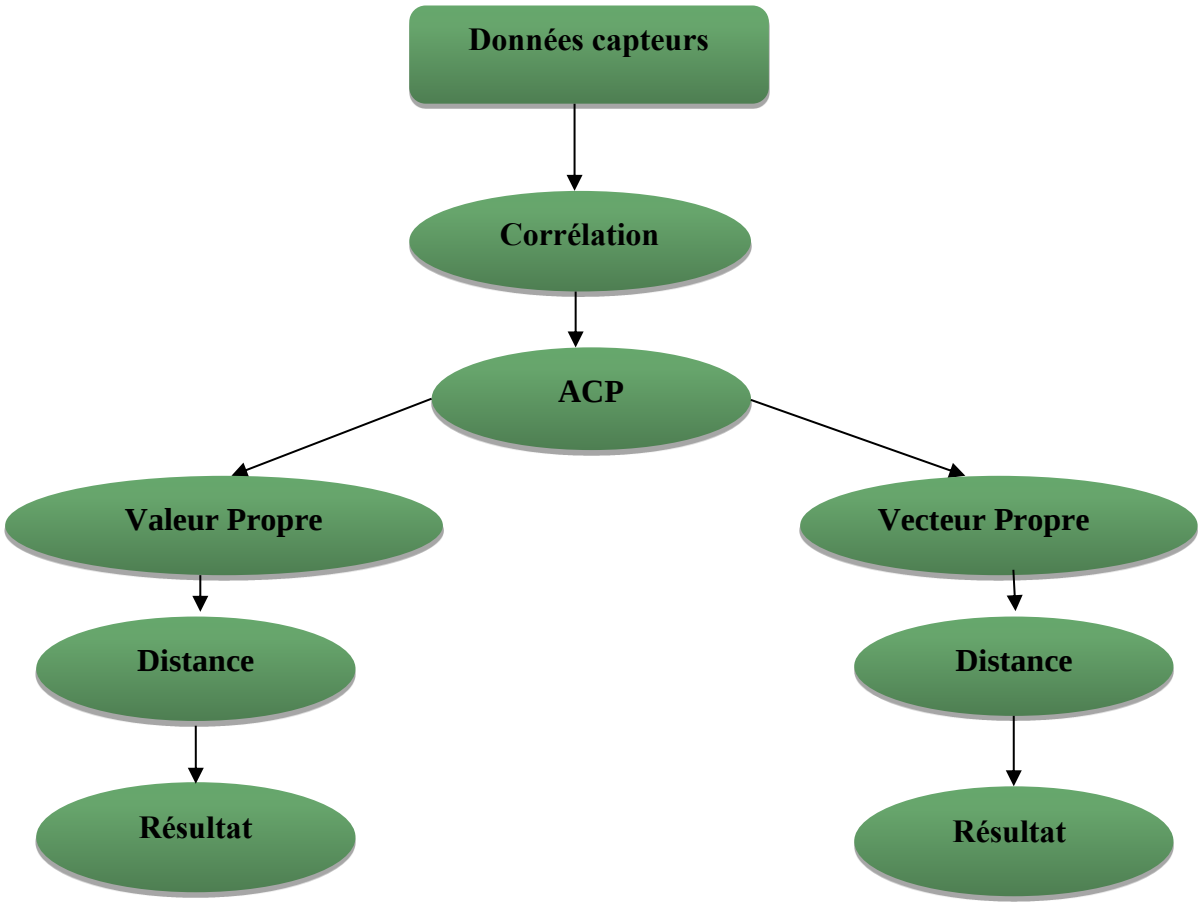


Figure II.8: Le schéma général de méthode globale proposée.

- **Donnée capteurs :** Nous avons récupéré les données qui sont stockées dans des fichiers avec différents format
- **Corrélation :** Nous avons appliqué cette méthode de sélection des variables pour garder les vecteurs moins corrélés.
- **PCA :** A partir de variables sélectionner correspondante à la matrice corrélé, on a appliqué le PCA pour réduite ces données en un seul composant par rapport aux temps
- **Distance :** On va calculer les distances du variable de réduction qui sont les valeurs propres et les vecteurs propres.

Après la création notre signal de chaque donnée tastée voir la Figure II.10. On obtient ces résultat :

- Pour les Vecteurs Propres : (p)

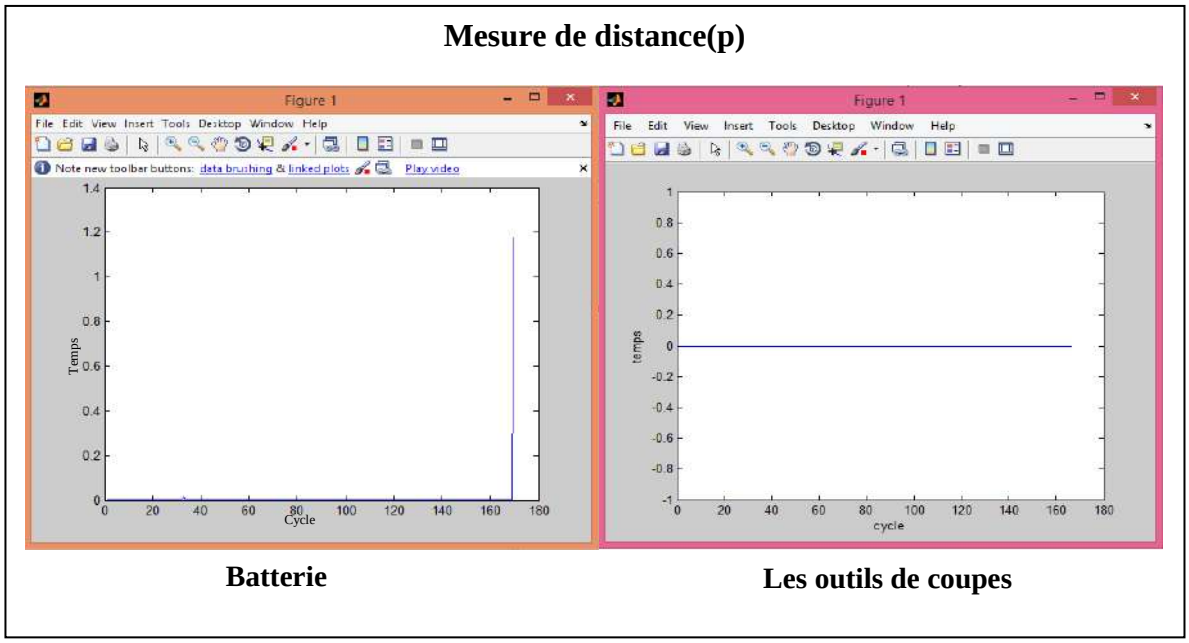


Figure II. 9: mesure de distance Vecteurs Propres (p)

On remarque que la mesure des distances entres les vecteurs propres ne donne pas de résultat pour les données turbofan. Cela veut dire que malgré le changement d'état les données gardent la même orientation de variation. Donc une distance nulle entre les vecteurs propres.

La conclusion est que la mesure de distance entre vecteur propre ne permet pas de détecter l'anomalie sur les données de dégradation des Turbofan, et ne peut donc pas être généralisée aux autres données.

- pour les Valeurs Propres (U) :

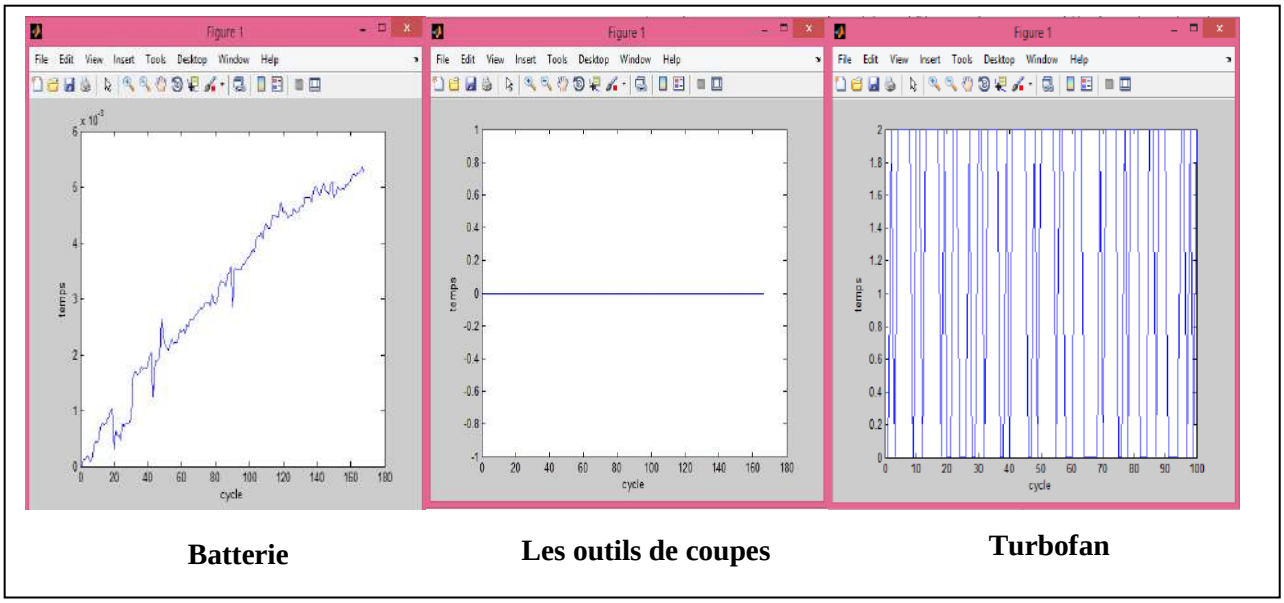


Figure II.10: Méthode de distance Valeurs Propres (U)

On remarque que la mesure des distances entres les valeurs propres donne des résultats :

- Pour les données Batterie :

On remarque que c'est un bon indicateur d'après l'orientation de variation de donnée on a détecté l'anomalie au cycle 33.

- Pour les données Outils de coupe :

Aucun changement d'état de ces valeurs donc une distance nulle entre les valeurs propres.

- Pour les données Turbofan :

On ne peut pas détecter l'anomalie parce l'orientation de variation de données est très bruités.

La conclusion est que la mesure de distance entre valeurs propre permet de détecter l'anomalie sur les données de dégradation des batteries seulement, et ne peut donc pas être généralisée aux autres données.

6.2 Méthode 02 : Caractéristiques temporelles

Dans le cas du PHM, l'extraction de caractéristiques repose essentiellement sur des techniques issues du traitement du signal. Leur utilisation suppose que l'apparition d'un défaut ou d'une dégradation conduit à une variation significative des paramètres statistiques du signal. Les caractéristiques extraites avec ces techniques peuvent être utilisées pour la détection de défauts. [33]

Dans notre cas, on a utilisé cette méthode dans le domaine temporelle. Elles permettent d'extraire des caractéristiques temporelles des signaux bruts. Parmi ces caractéristiques, on peut citer la moyenne, le carré de la moyenne quadratique (RootMean Square : RMS), la valeur pic, le kurtosis, le facteur de crête, etc..

.Dans le Tableau II. 2donne des exemples de caractéristiques temporelles et leurs formules mathématiques correspondantes.

La figure II. 12 suivantes montrent les caractéristiques temporelles obtenues sur des signaux obtenus de chaque donnée testées.

Tableau II. 2 : Exemples de caractéristiques temporelles

Caractéristique	Expression mathématique
Moyenne	$\frac{1}{N}\sum_{i=1}^{N}\lvert s_t(i)\rvert$
Carré de la moyenne quadratique	$\sqrt{\frac{1}{N}\sum_{i=1}^{N}s_t(i)^2}$
Valeur pic	$max(s_t)$
Facteur de crête	$\frac{VP(s_t)}{RMS(s_t)}$
Skewness	$\frac{1}{N}\sum_{i=1}^{N}\left[\frac{s_t(i)-\overline{s_t}}{\sigma_s}\right]^3$
Kurtosis	$\frac{1}{N}\sum_{i=1}^{N}\left[\frac{s_t(i)-\overline{s_t}}{\sigma_s}\right]^4$

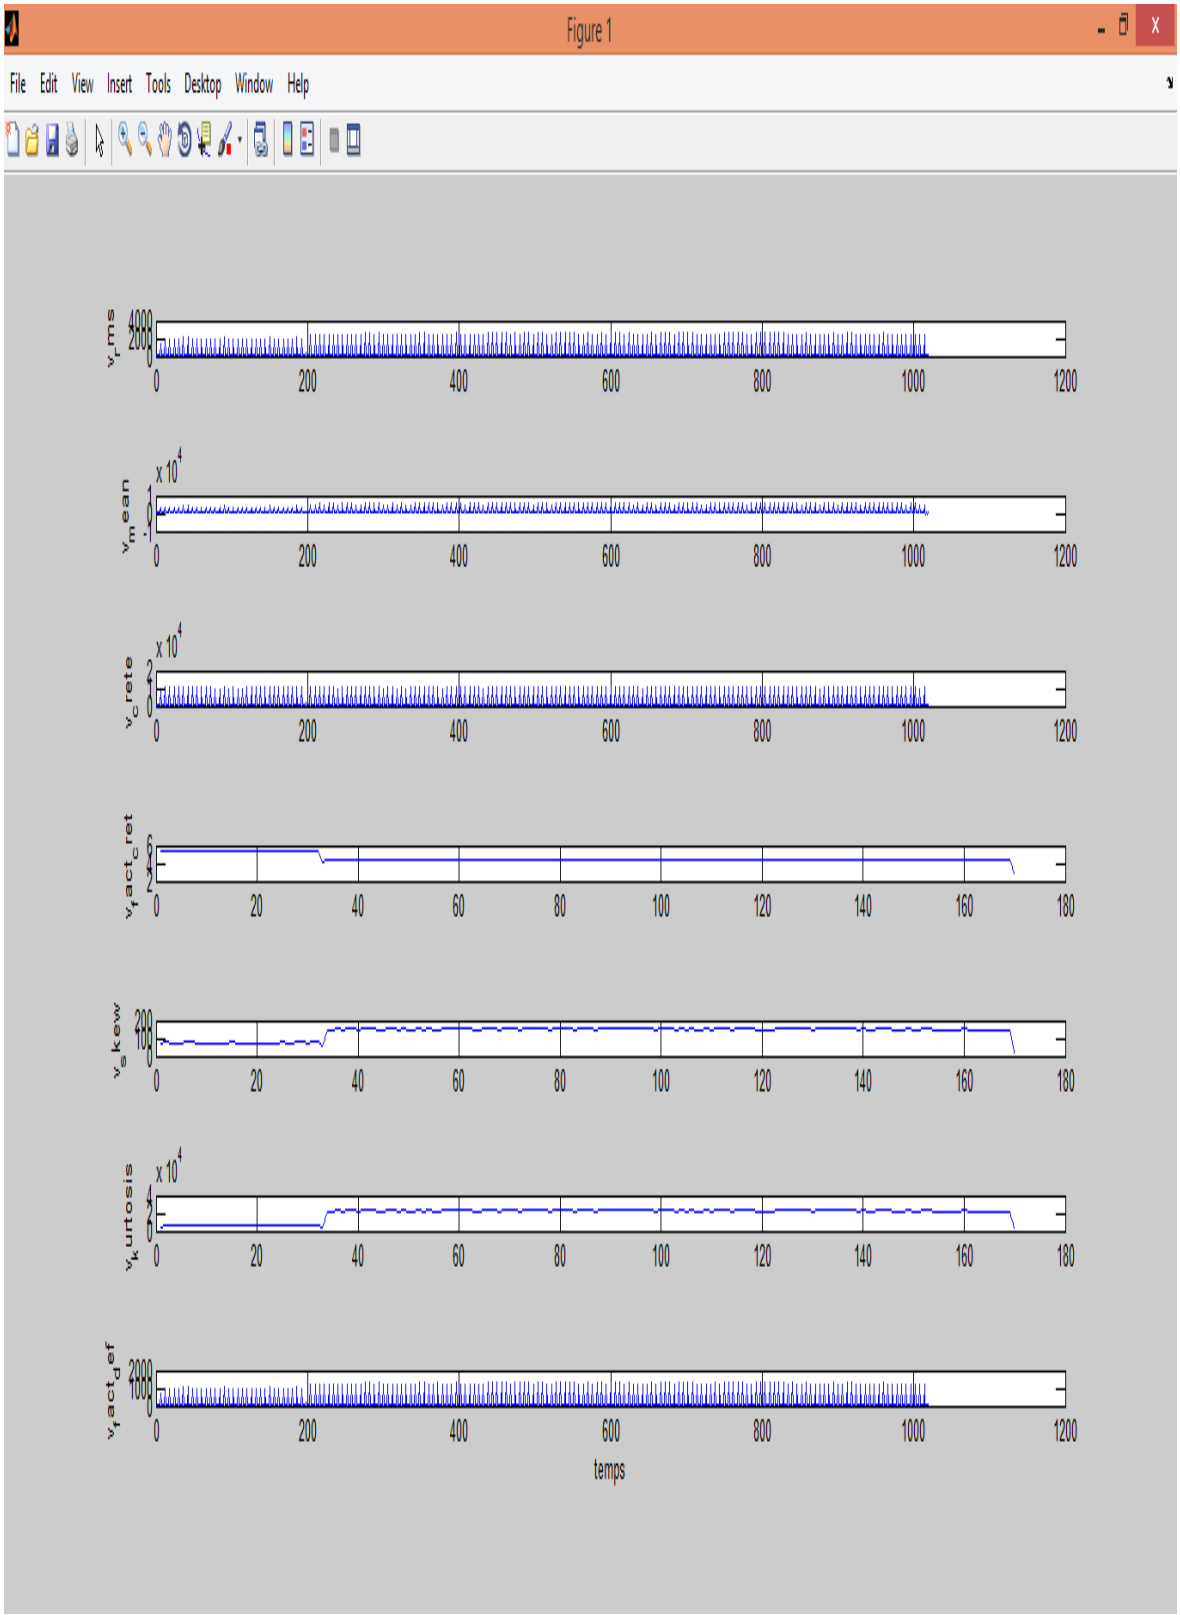


Figure II.11: Exemples de caractéristiques temporelles obtenues sur la batterie

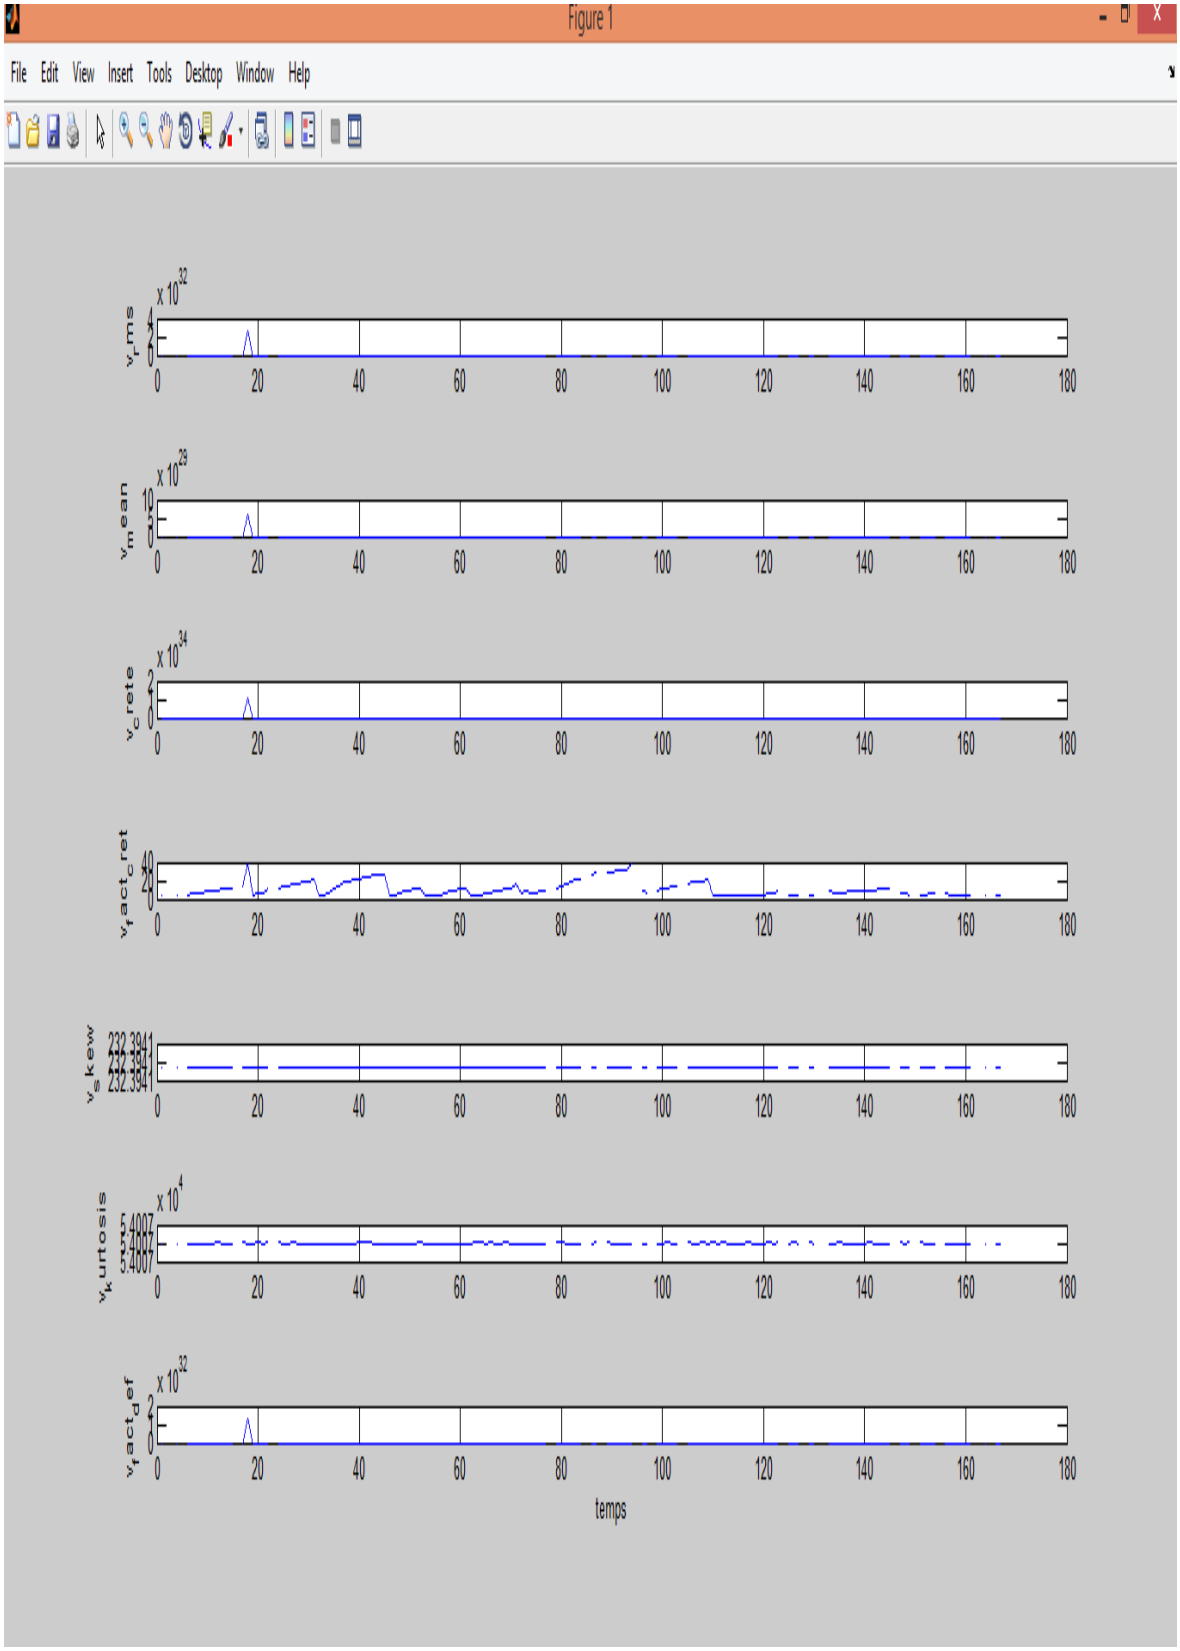


Figure II.12: Exemples de caractéristiques temporelles obtenues sur les outils de coupes

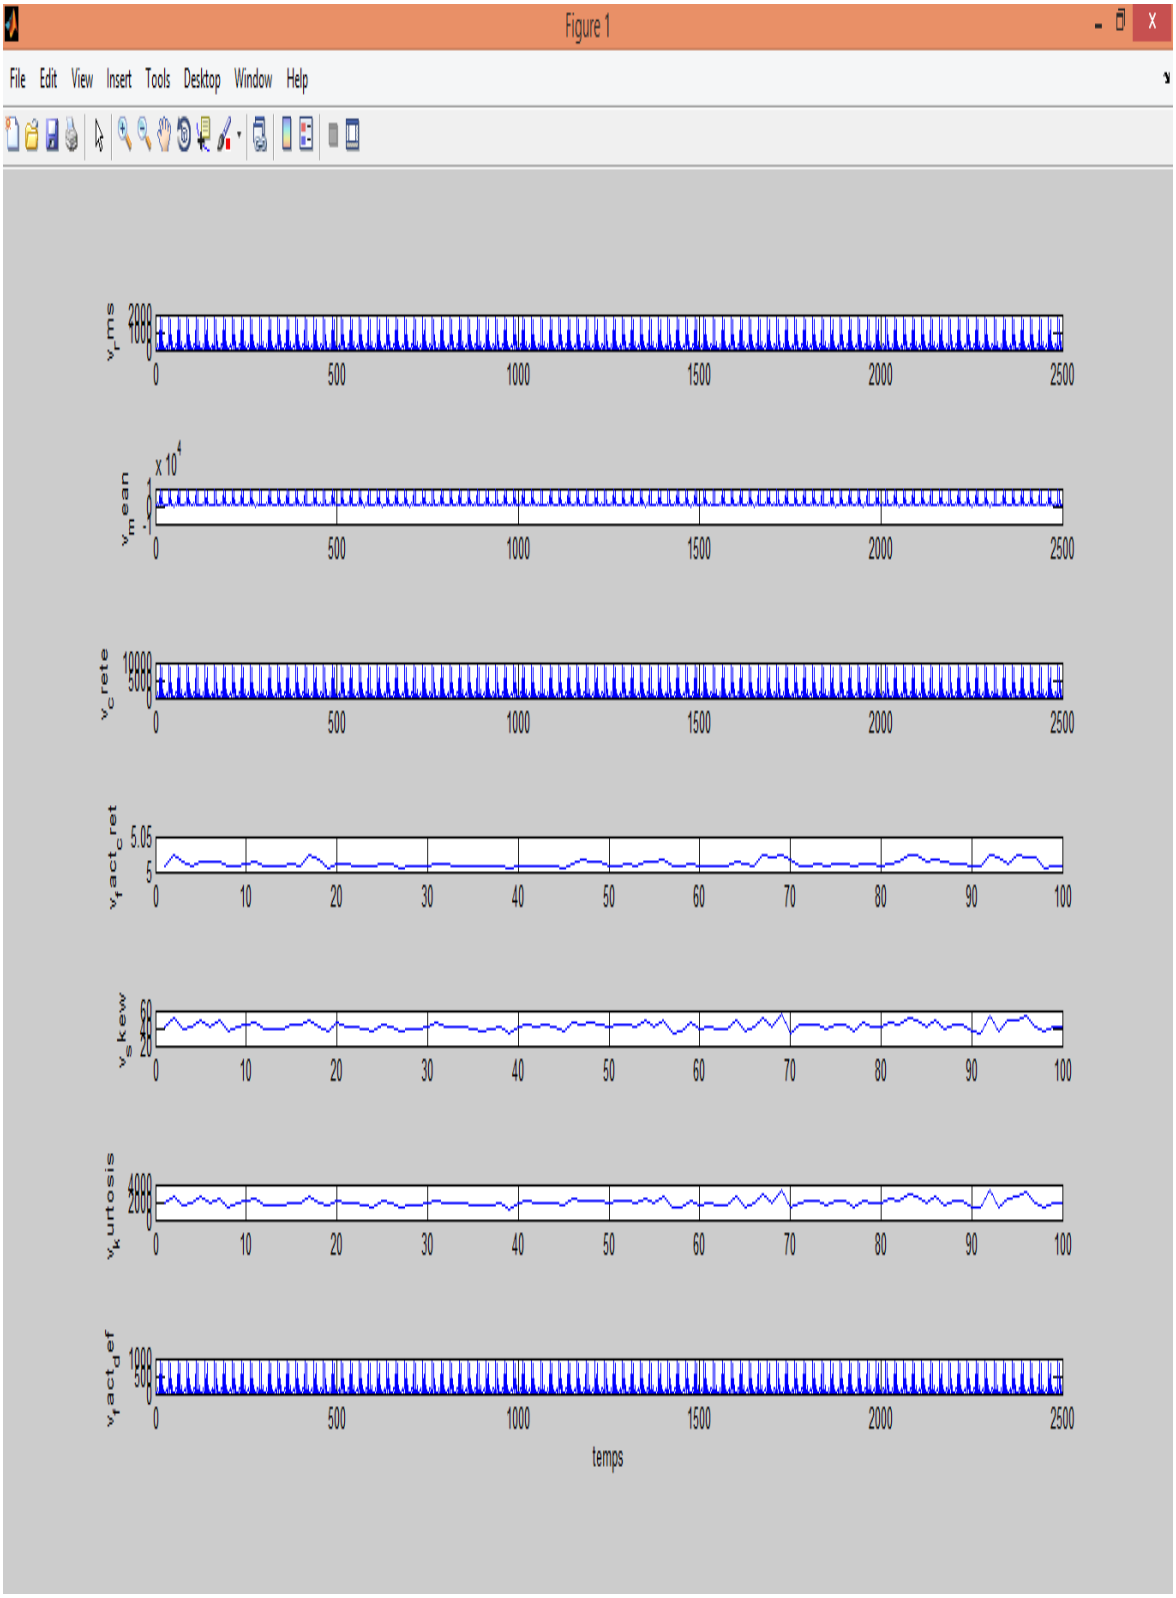


Figure II.13: Exemples de caractéristiques temporelles obtenues sur le Tourfan

Dans cette méthode, les données capteurs ne sont pas traitées directement. On extrait de ces données des caractéristiques (features) pour représenter au mieux le fonctionnement des batteries, outils de coupe et turbofan Puis les caractéristiques les plus pertinentes sont sélectionnées. à partir de données de chaque cycle, on extrait 7 caractéristiques : la moyenne, kurtosis, skewness, RMS ,facteur de crête, valeur de crête ,facteur défaut.

Les caractéristiques qui présentent des orientations de dégradations plus visibles sont choisies ce qui nous a menés à sélectionner comme feature et où l'anomalie détecté : facteur crête pour les batteries au cycle 33 et RMS pour les outils de coupe au cycle 18 et pour les turborfan on remarque malgré le changement d'états de ces caractéristique on n'a pas pu préciser l'anomale à quelle cycle apparaitre.

La conclusion est que la méthode de caractéristiques temporelles ne permet pas de détecter l'anomalie sur les données de dégradation des Turbofan, mais elle est plus globale à la méthode précédente et ne peut donc pas être généralisée aux autres données.

6.3 Méthode03 : Clustering

L'objectif de cette méthode est créé des regroupements en classes homogènes d'un ensemble d'individus. Les données se présentent en général sous la forme d'un tableau individus × variables. Ayant défini un critère de distance (dissemblance) ou dissimilarité (pas nécessairement d'inégalité triangulaire) entre les individus, on procède au regroupement des individus. Ce regroupement nécessite une stratégie de classification [34]

La mesure de distance est ensuite utilisée comme entrée dans un clusterage hiérarchique agglomérative (linkage single).

La méthode est appliquée sur le dendrogramme, À chaque itération, L'algorithme supprime chaque genou détecté et les points précédents. L'algorithme s'arrête quand il atteint la plus petite distance dans le dendrogramme. [14]

La figure suivante montre le dendogramme obtenu à partir du partitionnement sur les distances entre les variables.

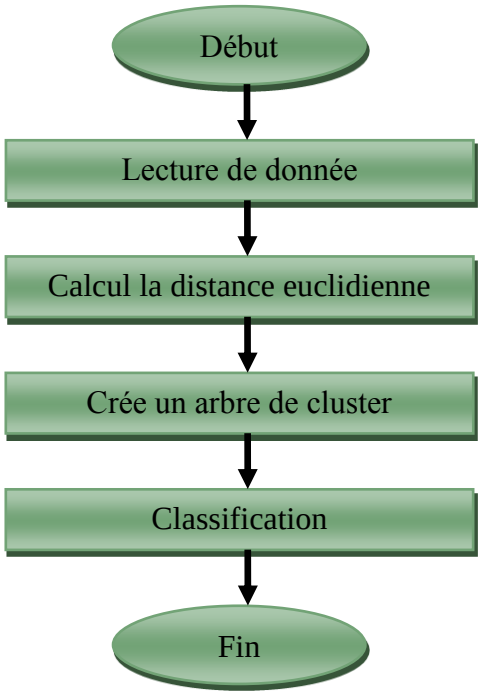


Figure II.14: Le schéma général de méthode de clustering

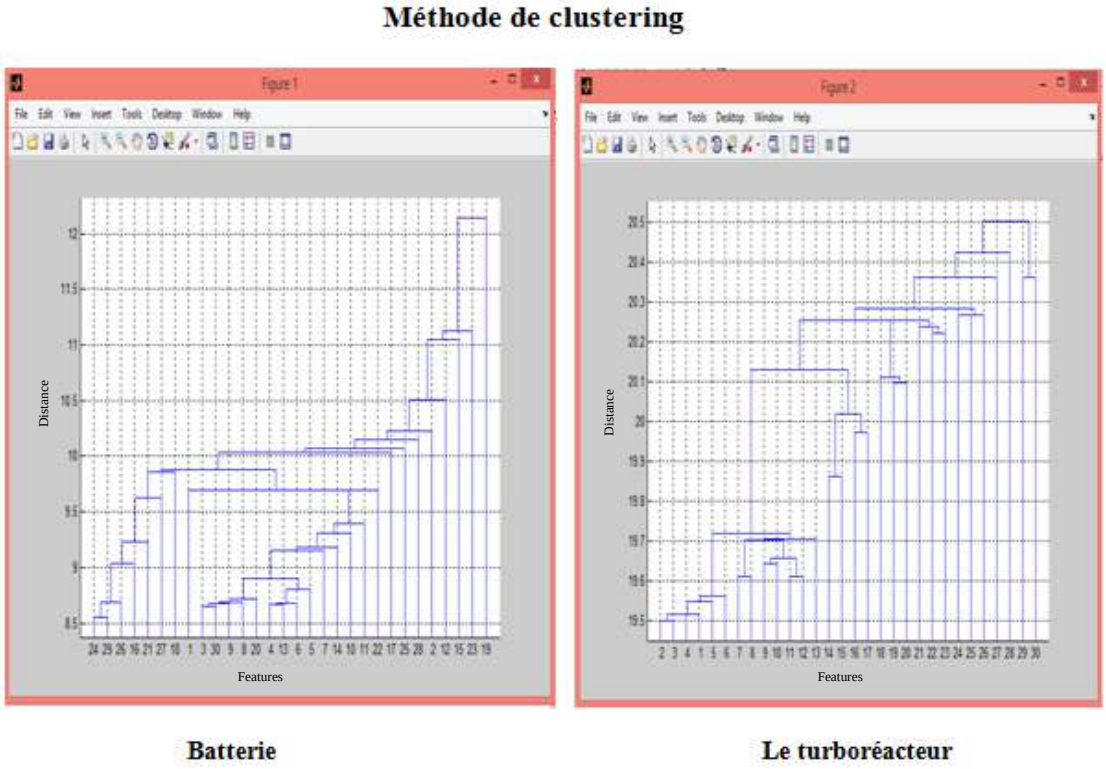


Figure II.15: le dendogram obtenu à partir du partitionnement sur les distances entre les variables sur les données testés

Par exemple, dans notre dendogramme obtenu de donnée Batterie et d'après notre recherche on veut obtenir avec la commande linkage deux classes c1 et c2 qui est au cycle 11.5

On conclut d'après cette méthode linkage qui est une méthode plus globale ou utilisable dans toutes les données testées et on peut généraliser aux autres données.

6.4 Méthode 04: Transformé de Fourier (FFT)

La technique la plus répandue pour extraire ce type de caractéristiques est la transformée de Fourier utilisée dans sa version discrète et rapide (Fast Fourier Transform : FFT)

Le résultat est une représentation dans le temps du spectre de fréquence du signal. Les fréquences extraites peuvent ainsi être utilisées pour détecter et diagnostiquer des défaillances de composants critiques, [35]

La figure suivante montre les spectres de fréquence du signal issu du chaque données.

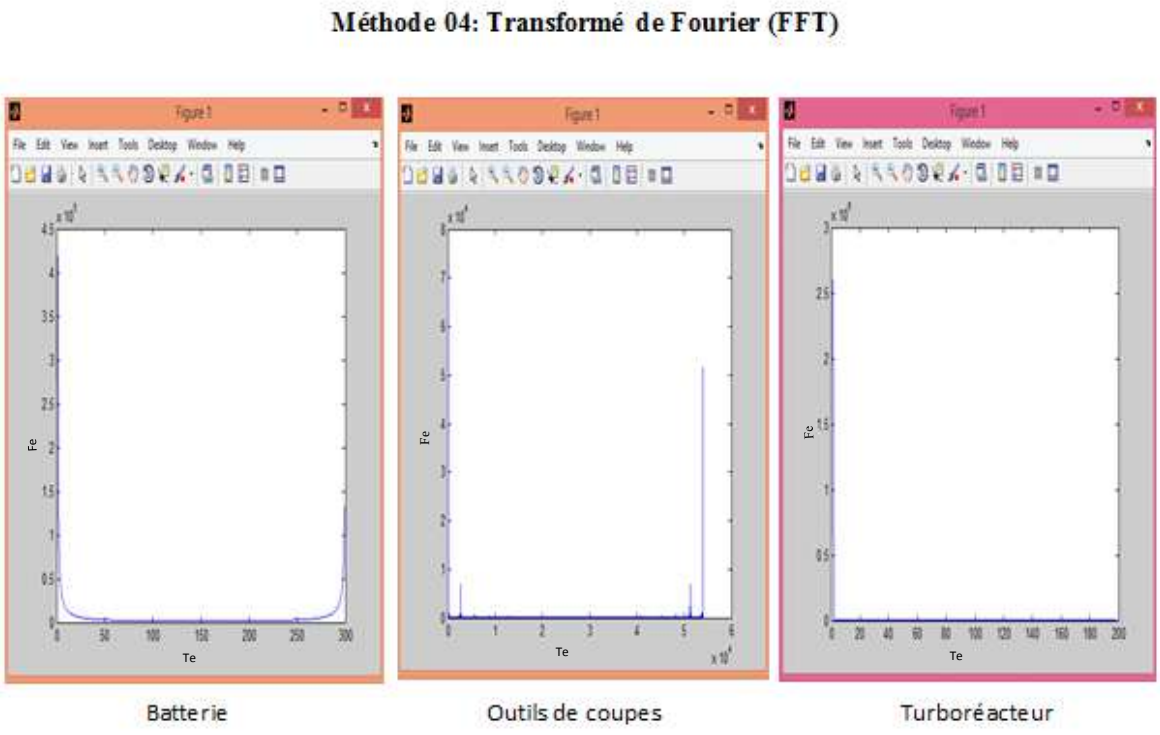


Figure II.16: FFT obtenue de chaque donnée testée

7. Conclusion

Nous avons proposés par l'approche basées sur les données pour prédire le RUL d'un composant critique à partir de son état courant, des méthodes de détection de défaillances ou anomalie qui sont appliquées sur différents type de données , les résultat obtenus sont compétitifs dépend la nature de données.

Dans ce chapitre nous avons abordé la problématique globale du traitement des données de surveillance pour extraire des caractéristiques après la sélection et la réduction des variables dans les domaines temporels et fréquentiels permettant de suivre l'état de santé de composants critiques. L'objectif est de transformer les signaux bruts fournis par les capteurs en informations utiles permettant ultérieurement de détecter le déclenchement d'une dégradation.

Le chapitre suivant nous aurons expliqués le principe de Réseaux de neurone RN qui nous intéresse pour la classification de données.

Chapitre III:
Réseaux de Neurones

1. Introduction

Avec l'avancée dans le domaine de la neurobiologie concernant le fonctionnement du cerveau et des neurones, des mathématiciens ont essayé de modéliser le fonctionnement du cerveau en intégrant ces connaissances en biologie dans des programmes informatiques pour leur donner la possibilité d'apprendre : c'est la naissance des réseaux de neurones.

Les opérations effectues par les opérateurs neuronaux peuvent être diverses, nous retiendrons dans ce chapitre la tâche de classification.

Nous présentons dans ce chapitre les réseaux de neurones. D'abord, nous donnons leur historique, nous décrivons ensuite les architectures neuronales les plus utilisées, Les critères de choix de réseaux de neurones Et enfin nous exposons les différents types d'apprentissages, ainsi que les domaines d'applications, et Avantages et Inconvénients.

2. Historique

La première modélisation d'un neurone date de 1943. Elle a été présentée par Mc-Culloch et Pitts. L'interconnexion de ces neurones permet le calcul de plusieurs fonctions logiques. En 1949, Hebb propose le premier mécanisme d'évolution des connexions, appelées (par analogie aux systèmes biologiques) des synapses. L'association de ces deux méthodes permit à Rosenblatt en 1958 de d'écrire le premier modèle opérationnel de réseaux de neurones: le perceptron. Celui-ci est capable d'apprendre à calculer un grand nombre de fonctions booléennes, mais pas toutes. Ses limites théoriques furent mises en évidence par Minsky et Paperten 1969. Depuis 1985, de nouveaux modèles mathématiques ont permis de les dépasser et ont donné naissance aux réseaux multicouches [36].

Aujourd'hui pas mal des recherches et applications ont été faites par les réseaux de neurones artificiels. Particulièrement dans le domaine de la surveillance et le diagnostic industriel, on trouve plusieurs articles, communications et travaux pratiques ont été faits dans ces dernières années.

3. Le Neurone

Un neurone est la cellule constituante de l'unité fonctionnelle du cerveau. Il est responsable de l'émission et de la propagation du message nerveux, nous allons expliquer très brièvement les bases biologiques dont ils sont originaires.

3.1 Le Neurone biologique

Le neurone est le processeur élémentaire du cerveau, chaque neurone traite l'information qui lui parvient localement, puis transmet aux autres neurones qui lui sont connectés l'information qu'il a traitée. Ces cellules peuvent apprendre en changeant l'intensité de leurs connexions avec d'autres cellules ou détruire ou même créer de nouvelles connexions. Elles peuvent aussi changer leur(s) règle(s) de traitement de l'information. Ce processus de changement est appelé apprentissage et joue un rôle fondamental dans le comportement du neurone [37].

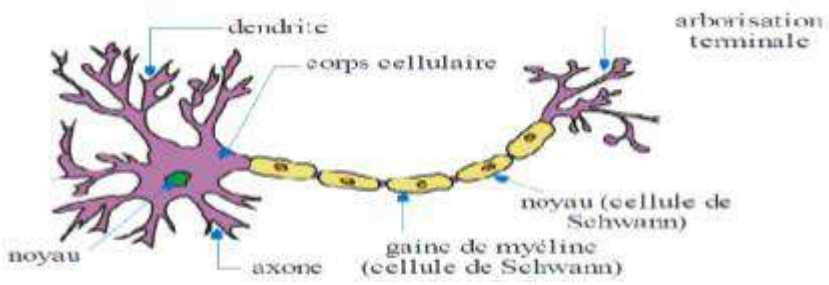


Figure III.1 : Représentation simplifiée d'un neurone biologique

3.2 Le Neurone artificiel (formel)

Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones amonts. A chacune de ces entrées est associé un poids w abréviations de weight (poids en anglais) représentatif de la force de la connexion. Ces neurones possèdent une fonction d'activation qui permet d'influencer les autres neurones du réseau [38]. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones avals. A chaque connexion est associé un poids [39

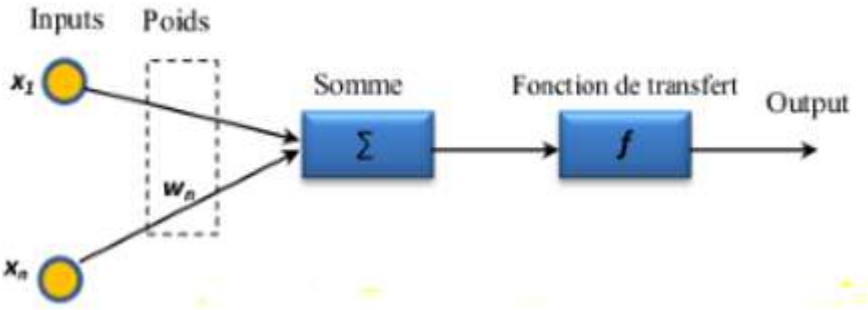


Figure III.2: Le neurone artificiel générique.

4. Modélisation d'un neurone formel

La modélisation consiste à mettre en œuvre un système de réseau neuronal sous un aspect non pas biologique mais artificiel, cela suppose que d'après le principe biologique on aura une correspondance pour chaque élément composant le neurone biologique, donc une modélisation pour chacun d'entre eux. Nous pouvons définir un neurone par les trois éléments suivants:

La fonction d'entrée totale qui définit le prétraitement effectué sur les entrées. La fonction d'activation (ou d'état) du neurone qui définit son état interne en fonction de son entrée totale.

La fonction de sortie qui calcule la sortie du neurone en fonction de son état d'activation. Les neurones artificiels reprennent cette structure comme le montre la Figure III.3 :

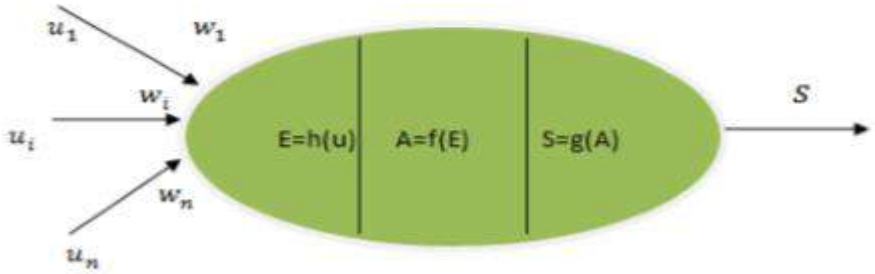


Figure III.3 : Modèle général d'un neurone formel

Où:

ui : Entrées du neurone (i=1,….n), qui peuvent être des grandeurs réelles ou binaires.

wi : Coefficient de pondération de l'entrée i.

h(): Fonction d'entrée totale, qui peut être une combinaison booléenne des entrées, une combinaison linéaire des entrées.

f(): Fonction d'activation, qui prend généralement les formes suivantes [38] : une fonction binaire à seuil Figure III.4a, une fonction linéaire à seuil ou seuils multiples Figure III.4b, Figure III.4c et Figure III.4d, une fonction sigmoïde Figure III.4e, une fonction à base radiale Figure III.4f.

g () : Fonction de sortie

E=h(E) : Entrée totale ou degré d'activation.

A=f(E): Etat du neurone.

S=g(A): Sortie est souvent considérée comme la fonction identité.

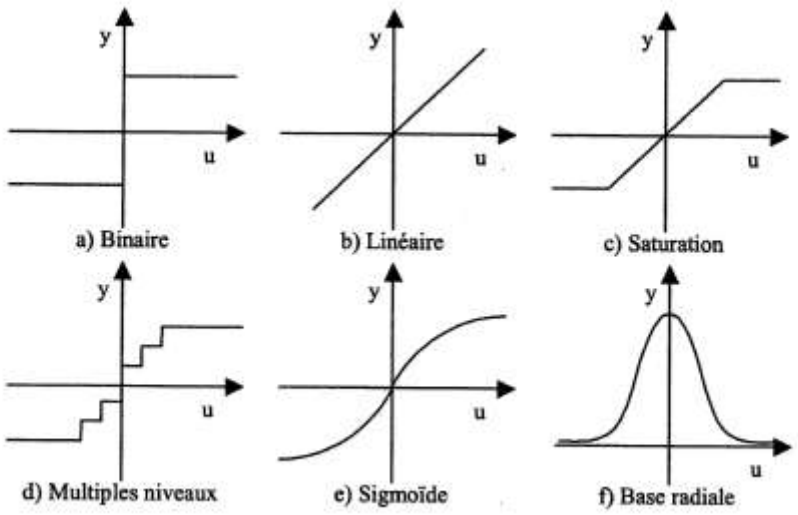


Figure III.4 : Fonctions de sortie des neurones

5. Les critères de choix de réseaux de neurones artificiels

Il existe une grande variété de réseaux de neurones artificiels, ceux-ci pouvant être définis selon plusieurs critères, parmi lesquels, on peut citer:

- Déférentes architectures de réseaux de neurones;
- Mécanisme d'apprentissage;
- L'apprentissage des réseaux multicouches
- Principe de descente gradient.

5.1. Architecture de réseaux de neurones

Selon la topologie de connexion des neurones, on peut les classer en deux grandes catégories: réseaux non bouclés (statique ou feedforward) et réseaux bouclés (dynamique, feed back ou récurrent). [40]

A. Un réseau de neurones non bouclé

Réalise une (ou plusieurs) fonction algébrique de ses entrées par composition des fonctions réalisées par chacun de ses neurones. Dans un tel réseau Figure III.5 [41], le flux

d'information circule des entrées vers les sorties sans retour en arrière. Si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes sont les « Connexions » entre ceux-ci, le graphe d'un réseau non bouclé est acyclique.

Tout neurone dont la sortie est une sortie du réseau est appelé « neurone de sortie », les autres, qui effectuent des calculs intermédiaires, sont des « neurones cachés ».

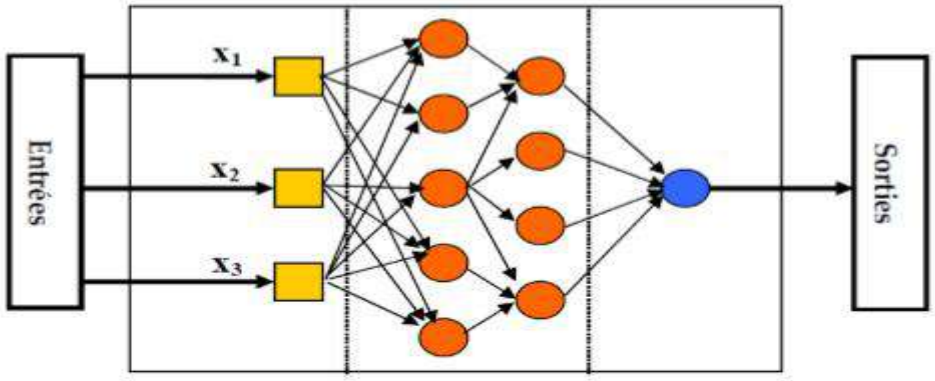


Figure III.5 : Réseau de neurone non bouclé

B. Réseaux de neurones bouclés

L'architecture la plus générale pour un réseau de neurones est le « réseau bouclé », dont le graphe des connexions est cyclique : lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (un tel chemin est désigné sous le terme de « cycle »).

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Pour éliminer le problème de la détermination de l'état du réseau par bouclage, on introduit sur chaque connexion « en retour » un retard qui permet de conserver le mode de fonctionnement séquentiel du réseau Figure III. 6[40].

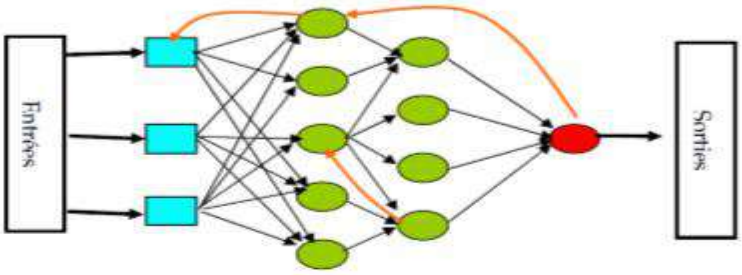


Figure III.6 : Réseau de neurones bouclé

5.2 Apprentissage pour un RN

A. Définition

Comme le cerveau humain, les réseaux de neurones artificiels (RNA) peuvent apprendre par expérience. L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux Neuronaux. Elle ne concerne cependant pas tous les modèles, mais les plus utilisés.

L'apprentissage est une phase du développement du réseau de neurones durant laquelle on calcule les poids des neurones de telle manière que les sorties du réseau soient aussi proche que possible des sorties désirées [40].

L'apprentissage consiste à trouver le réseau qui fournit la meilleure solution au problème qu'il doit résoudre, pour un ensemble de données dites d'apprentissage. Cela est réalisé en adaptant, grâce à certaines règles, les vecteurs de poids. Ce concept d'apprentissage n'est vraiment intéressant que si le réseau possède des capacités de généralisation, c'est-à-dire qu'il est capable de fournir une bonne solution pour d'autres données.

Après initialisation des poids du réseau (en générale des valeurs aléatoire), il y a présentation des exemples au réseau et calcul des sorties correspondantes, une valeur d'erreur ou de correction est calculée et une correction des poids est appliqués. Les procédures d'apprentissage peuvent se subdiviser, en trois grandes catégories : Apprentissage supervisé, non supervisé et semi supervisé (renforcement).

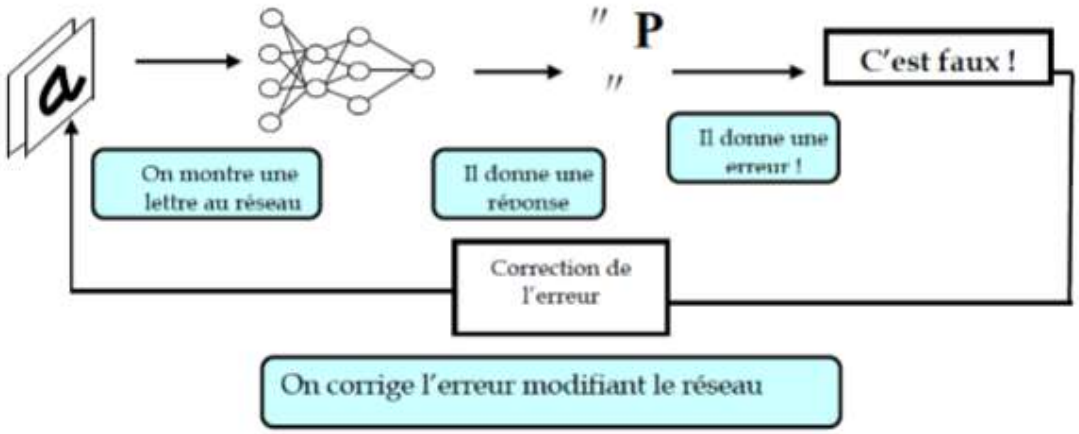


Figure III.7 : Exemple d'apprentissage

B. Apprentissage supervisé (avec professeur)

Dans l'apprentissage supervisé, un superviseur fournit une valeur ou un vecteur de sortie (appelé cible ou sortie désirée) que le réseau de neurones doit associer au vecteur d'entrée, donc l'apprentissage supervisé implique l'existence d'un ≪ professeur ≫ qui a pour rôle d'évaluer le succès (ou l'échec) du réseau quand il lui est présente un stimule connu [42].

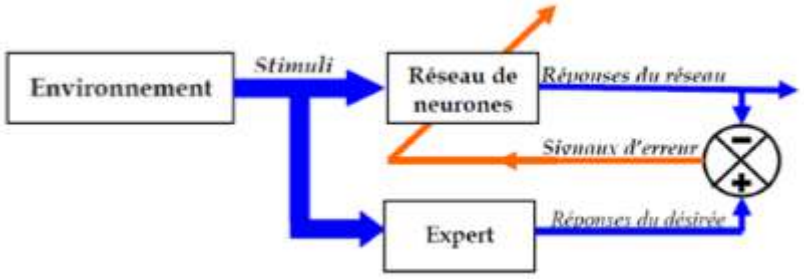


Figure III.8 : Illustration d'apprentissage supervisé

C. Apprentissage non supervisé

Dans l'apprentissage non supervisé, les données ne contiennent pas d'informations sur une sortie désirée, il n'y a pas de superviseur ≪ ou expert humain ≫. Il s'agit de déterminer les paramètres du réseau de neurones suivant un critère à définir.

Dans ce cas, les exemples présents à l'entrée provoquent une auto adaptation du réseau afin de produire des valeurs de sortie qui soient proche en réponse pour des valeurs d'entrées similaires. La Figure III.9 illustre, un exemple d'apprentissage non supervisé. Les RNAs qui utilisent ce type d'apprentissage sont appelés ≪ auto organisatrice ≫ ou ce type d'apprentissage possède souvent une moindre complexité dans le calcul par rapport à l'apprentissage supervisé.

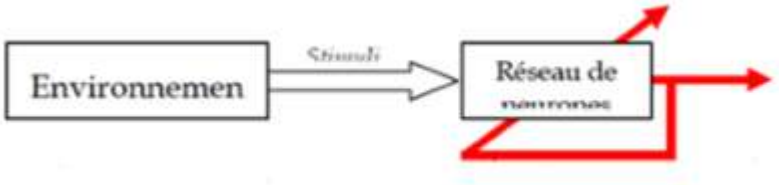


Figure III.9 : Illustration d'apprentissage non supervisé

5.3 L'apprentissage de réseau multicouche

Les réseaux multicouches sont aujourd'hui les modèles les plus employés. Plusieurs couches de traitement leurs permettent de réaliser des associations non linéaires entre

l'entrée et la sortie. Ils sont ainsi capables de résoudre le cas du perceptron. On sait depuis les années 60 que les possibilités de traitement des réseaux multicouches sont supérieures à celle du perceptron, cependant l'algorithme d'apprentissage manquait.

5.4 Principe de descente de gradient (propagation de gradient)

Cette méthode est utilisée couramment dans de nombreuses applications. Elle consiste à rechercher un endroit situé plus bas que tous les autres endroits (c'est-à-dire le minimum), alors le déplacement sera systématiquement vers le bas Figure III.10 en suivant les lignes de plus grande pente, celle-ci étant mathématiquement calculée par le gradient [43].

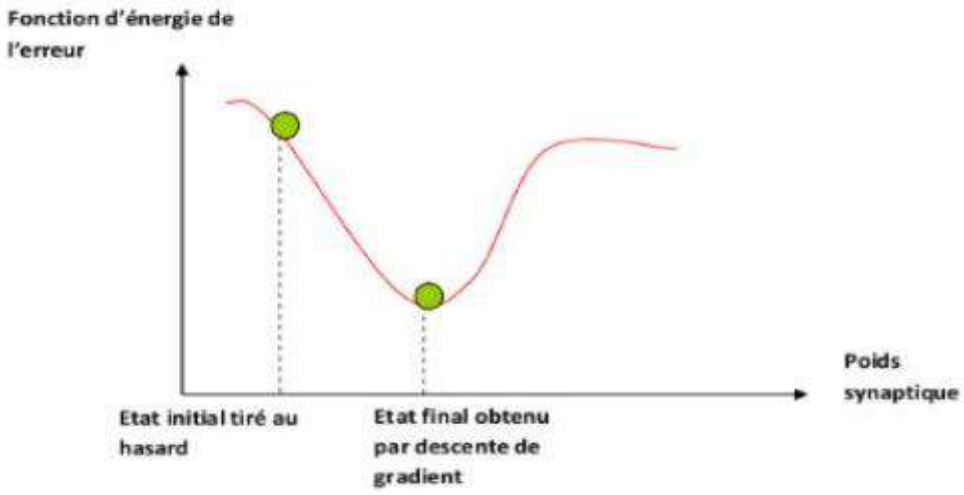


Figure III.10: Descente de gradient

6. Techniques de l'intelligence artificiels

- Alternative aux méthodes traditionnelles
- Surmonter les limitations
- Ne nécessitent pas de modélisation exacte
- Simplicité de modification et d'extension
- Ce qu'elles nécessitent Minimum d'expertise et de données

7. Domaines d'application des réseaux de neurones (RNA)

Les RNA aujourd'hui ont des applications dans des domaines variés parmi lesquelles on cite :

- Reconnaissance de formes
- Traitement de la parole
- Détection d'anomalies
- Traitements dépendant du temps [44]

8. Avantages et Inconvénients des réseaux de neurones

8.1 Avantages des réseaux de neurones

- Capacité de représenter n'importe quelle fonction, linéaire ou pas, simple ou complexe.
- Faculté d'apprentissage à partir d'exemples représentatifs, par « rétro propagation des Erreurs ». L'apprentissage (ou construction du modèle) est automatique.
- Résistance au bruit ou au manque de fiabilité des données.
- Simple à manier, beaucoup moins de travail personnel à fournir que dans l'analyse statistique classique. Aucune compétence en matis, informatique statistique requise.
- Comportement moins mauvais en cas de faible quantité de données.
- Pour l'utilisateur novice, l'idée d'apprentissage est plus simple à comprendre que les complexités des statistiques multi variables [44].

8.2 Inconvénients des réseaux de neurones

- L'absence de méthode systématique permettant de définir la meilleure topologie du réseau et le nombre de neurones à placer dans la (ou les) couche(s) cachée(s).
- Le choix des valeurs initiales des poids du réseau et le réglage du pas d'apprentissage qui jouent un rôle important dans la vitesse de convergence.
- Le problème du sur apprentissage (apprentissage au détriment de la généralisation).
- La connaissance acquise par un réseau de neurone est codée par les valeurs des poids sont inintelligibles pour l'utilisateur [44].

9. Conclusion

Ce chapitre est un peu court pour résumer toutes les notions principales de réseaux de neurones et leur apprentissage. A cet effet, il est à rappeler qu'un réseau de neurones n'est

rien d'autre qu'une approximation de fonctions basé sur l'interconnexion de plusieurs entités élémentaires appelées neurones. 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.

Le chapitre suivant est consacré pour la classification les méthodes que nous avons testées pour extraire une méthode générique de la détection des anomalies

Chapitre IV :
Détection d'anomalies par classification neuronele

1. Introduction

Dans cette partie nous allons décrire le fonctionnement de notre application pour la détection par le réseau sur les descripteurs extraits par les différentes méthodes testées sous le langage Matlab. Une architecture générale de l'application, les tests. A la fin, le tableau final des résultats qui résume notre recherche.

2. Matlab

Matlab (*Matrix LABoratory*) est un logiciel de calcul scientifique base sur la manipulation des matrices avec des fonctionnalités mathématiques, il est permet d'afficher des courbes de manière facile.

Il possède des syntaxes de programmation simples et efficaces, constituées de :

- de nombreux outils du calcul matriciel,
- des principaux algorithmes de l'analyse numérique (schémas d'intégration, interpolation, différentiation...),
- des outils pour le traitement du signal.
- des outils de visualisation en 2D et 3D.

3. Toolbox NFTOOL de Matlab

Le TOOLBOX NFTOOL « Neural Network Fitting Tools» de Matlab est un outil puissant, utilisé pour l'application de l'algorithme de rétro propagation « back-propagation (BP) », qui permet de fait l'apprentissage et la classification des données.

Pour lancer le TOOLBOX NFTOOL on exécute l'instruction « nftool » dans la zone de travail «Workspace» du MATLAB.

Après avoir exécuté la commande «nftool», apparait une représentation pour l'appel de Toolbox nftool Matlab.

Par la suite on fait le chargement et la sélection des entrées « inputs » et les Sorties « targets ».

Après cas on choisir les pourcentages d'apprentissage, validation et teste.

Par la suite on choisir le nombre de neurones dans La couche cachée.

Pour obtient L'apprentissage de notre réseau de neurone on fait le « train ». [5]

4. Architecture générale de l'application

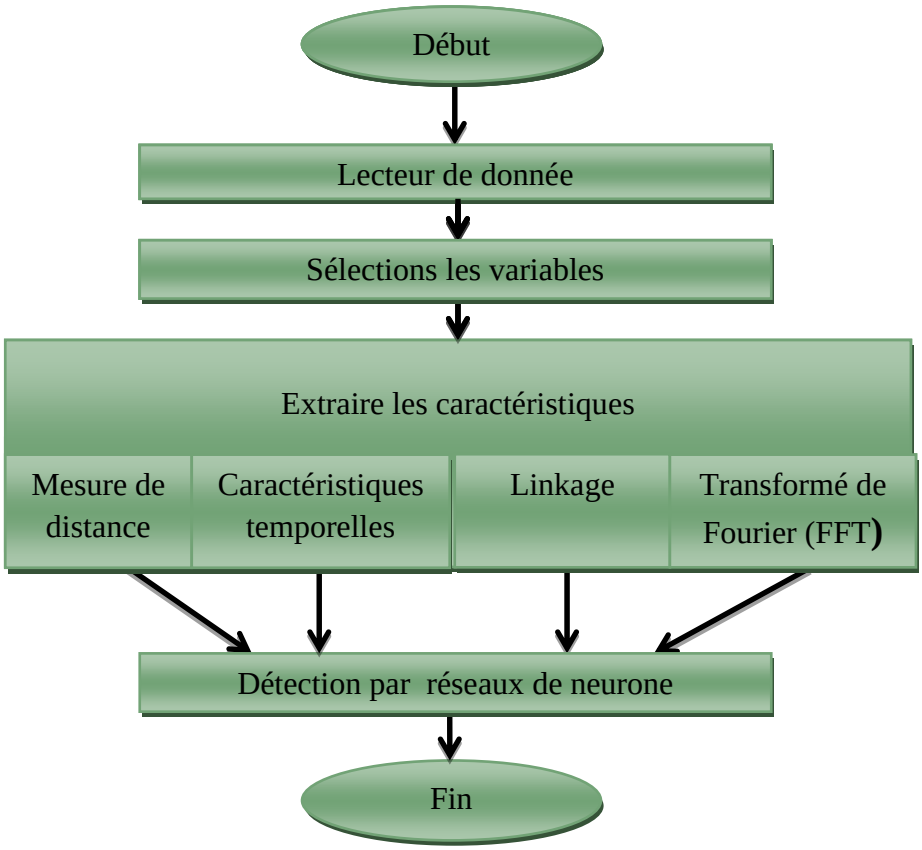


Figure IV .1 : Architecture générale de l'application

5. Explication de l'architecture générale de l'application

- **Lecteur de donnée :** lecteur des données qui sont stockées dans des fichiers Excel, fichiers texte et fichiers Matlab.
- **Sélection les variables :** On applique cette méthode de sélection des variables pour garder les vecteurs moins corrélés
- **Extraire les caractéristiques:** Faire les calcule par les six paramètres statistiques temporels (RMS, Moyenne, Skwness, Kurtosis, Facteur de crête, Facteur de défaut)
- **Classification par les réseaux de neurone :** Où la sortie sont les descripteurs devient l'entrée de RN, on a utilisé deux classes pour classer l'état de santé du système (c1 c'est l'état normal, c2 c'est l'état dégradée).

6. Architecture du Réseau de neurone

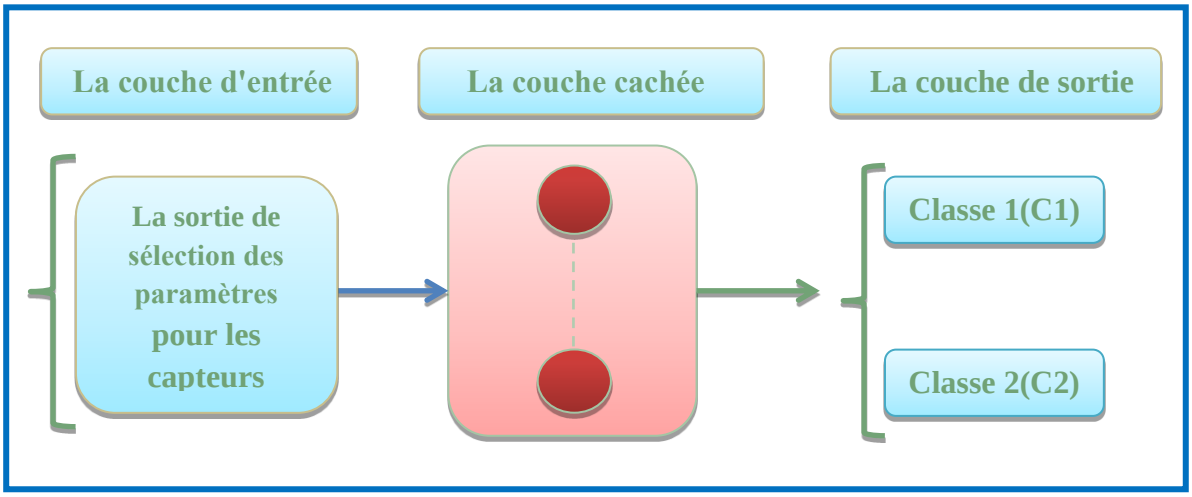


Figure IV.2 : Architecture de Réseau de neurone.

7. Applications

L'application a pour but de minimiser l'erreur entre la sortie réelle (**Yr**) c'est-à-dire la sortie de réseau de neurones et la sortie désirée (**Yd**) afin de faire la meilleure classification puis l'apprentissage de ce **RN** suivant les étapes suivantes :

- **1:** Sortir la fenêtre de Neural Network FittingTool par la commande "*nftool*" qui est écrié sur l'espace Matlab.

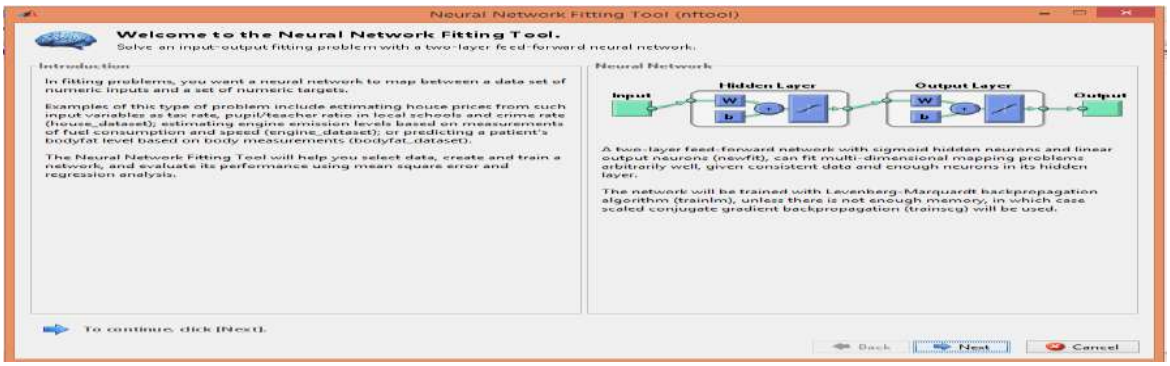


Figure IV.3 : Affichage de la fenêtre nftool.

- **2:** Choie du nom du données d'entrée "*input data*" et de sortie "*targets data*".

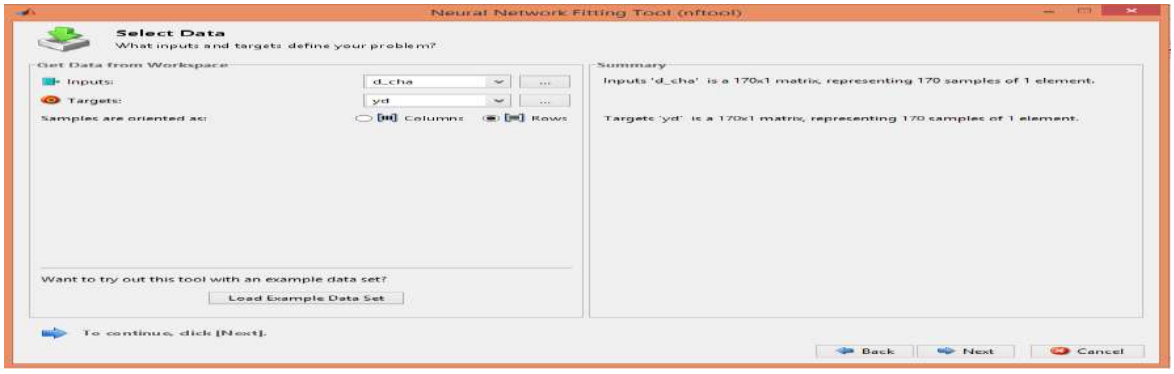


Figure IV.4 : Chargement des entrées et des sorties de programme.

- **3:** Choie du pourcentage de "Testing = 5%" et "Validation = 5%" pour être la valeur de "Traing = 90%", c'est à dire le plus grand nombre de valeurs d'apprentissage

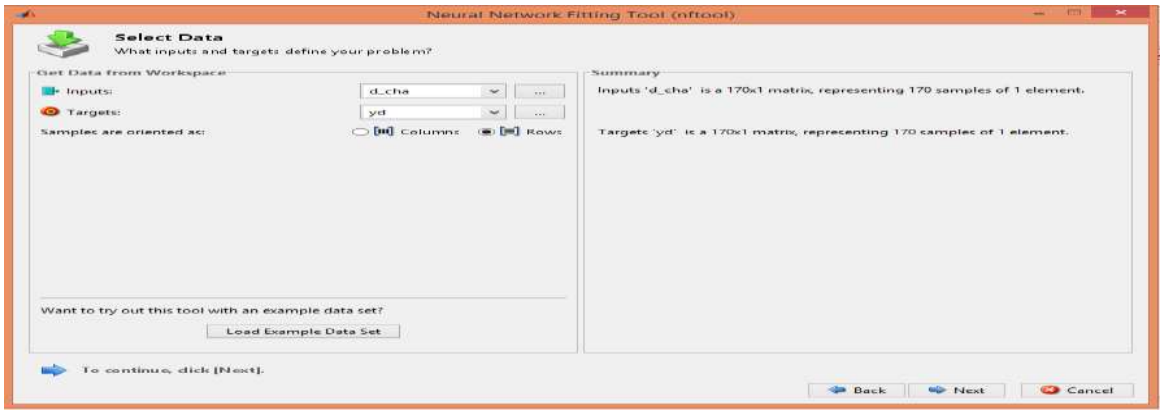


Figure IV.5 : Chargement des pourcentages.

- **4:** Choie du nombre de neurone dans la couche cachée (Nb= 10).

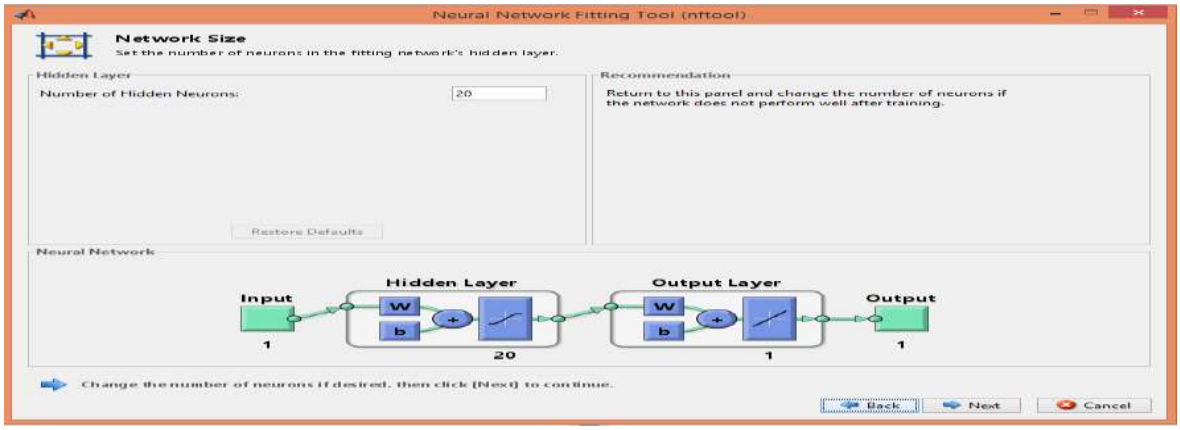


Figure IV.6 : Choix du nombre de neurones dans la couche cachée.

Les étapes précédentes sont les mêmes dans tous les méthodes appliquées

7.1 Méthode de distance (p)

A. La batterie

- **5:** Clique sur "*Train*" pour sortir l'erreur.

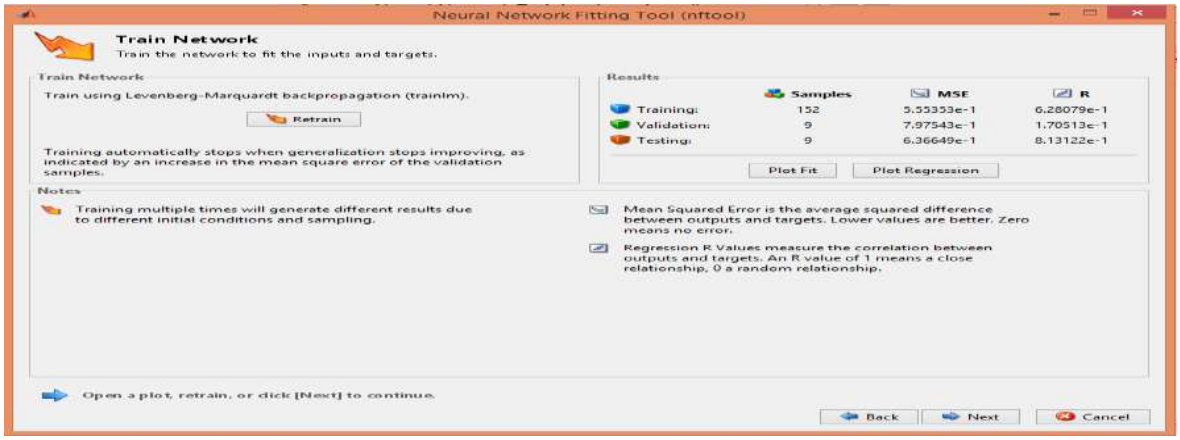


Figure IV.7 : Démarrage de l'apprentissage.

- **6:** La fenêtre de Neural Network Training.

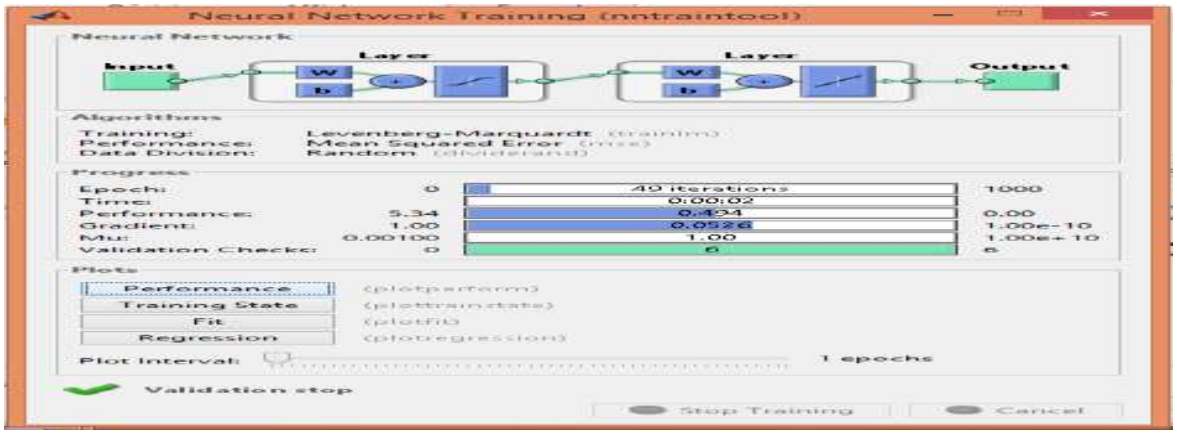


Figure IV.8: Résultat de l'apprentissage.

- **7:** La performance.

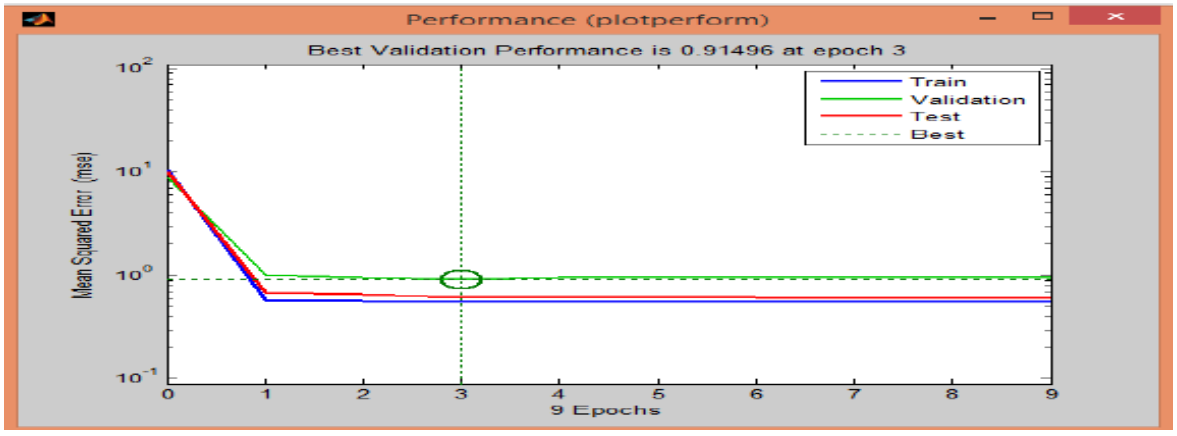


Figure IV.9: Affichage des graphes de performance (MSE).

- **8:** Nommer et sauvegarder le réseau de neurones.



Figure IV.10 : Nommer et sauvegarder le RN

- **9:** Affichage du Yd.

```
    -1
    -1
    -1
    -1
    -1
    -1
     1
     1
     1
     1
     1
     1
     1
     1
     1
     1
     1
     1
```

Figure IV.11 : Exemple de l'affichage de la sortie "Yd".

- **10:** Affichage de Yr.

```
>> yr=sim(net,d_cha')'

yr =

   -0.1717
    0.4034
    0.3644
    0.3644
    0.4034
    0.4421
    0.4421
    0.3251
    0.3251
    0.3251
    0.3251
    0.2855
    0.2053
    0.2855
    0.4421
    0.2855
    0.3251
    0.3251
    0.3251
    0.3251
    0.3644
    0.3251
    0.3251
```

Figure IV.12: Exemple de l'affichage du "Yr".

- **11:** Affichage du l'erreur. Erreur=yd-yr

```
0.4815
0.4438
0.3693
0.4438
0.3693
0.4064
0.4438
0.3325
0.3325
0.4064
0.4438
0.4438
0.3325
0.3325
0.4064
0.3325
0.4815
0.5579
0.4815
0.5579
0.3693
0.4815
0.4438
0.4064
0.3693
0.3325
0.3693
```

Figure IV.13: Exemple de l'affichage du l'erreur

Pour les outils de coupe et turbofan on ne peut pas faire l'apprentissage parce que le changement d'état les données gardent la même orientation de variation. Donc une distance nulle entre les vecteurs propres.

7.2 Méthode de distance (u)

A. La batterie

- **5:** Clique sur "*Train*" pour sortir l'erreur.

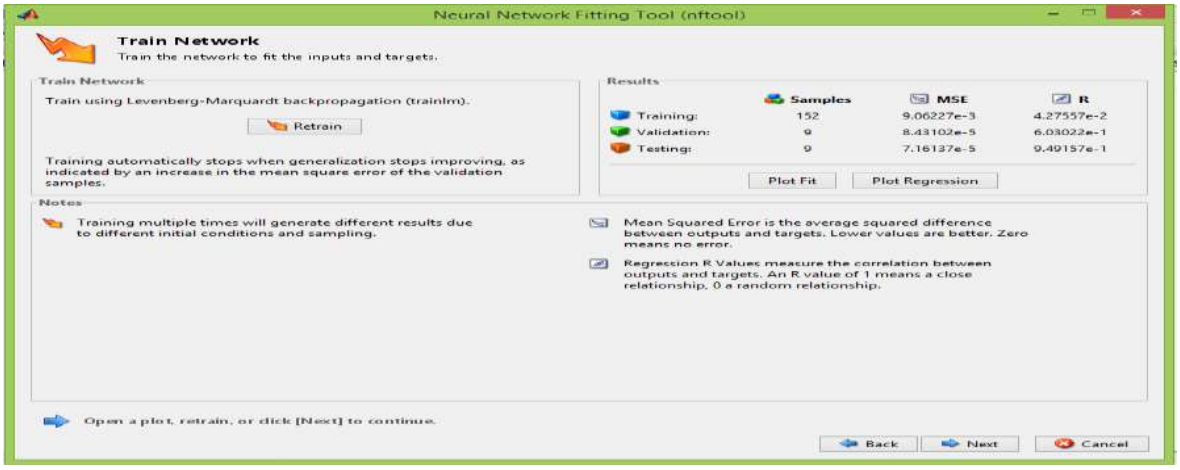


Figure IV.14 : Démarrage de l'apprentissage.

➢ **6:** La fenêtre de Neural Network Training.

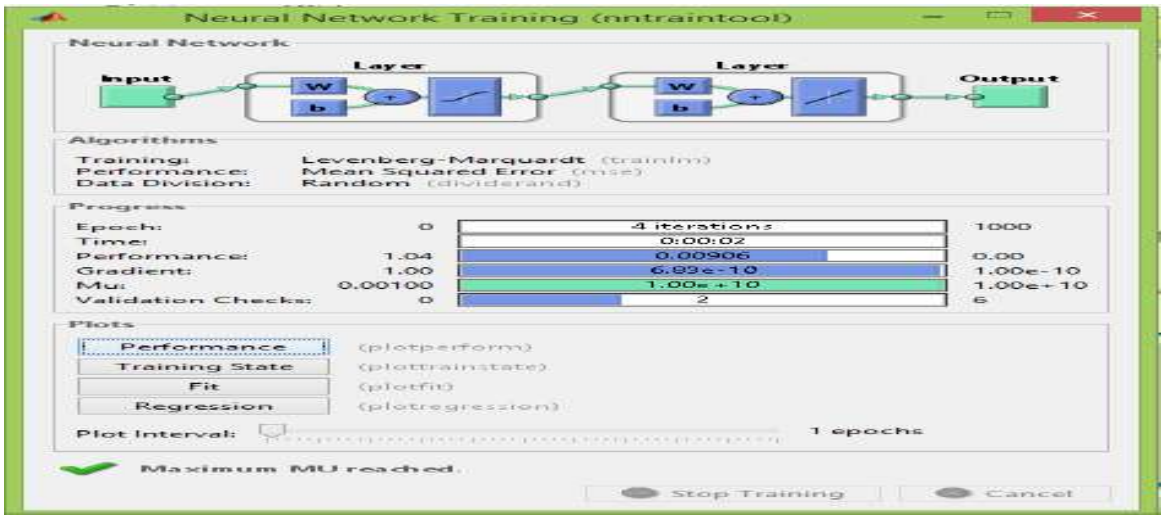


Figure IV.15 : Résultat de l'apprentissage.

➢ **7:** La performance.

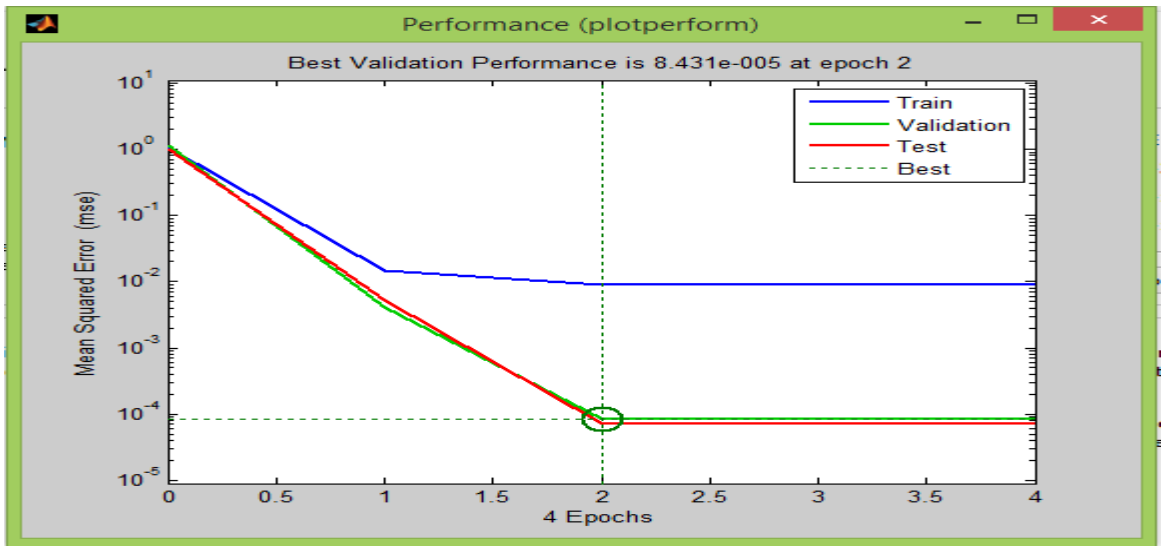


Figure IV.16 : Affichage des graphes de performance (MSE)

- **8:** Affichage de Yr

```
>> yr=sim(net,yd')'

yr =

   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
   -0.9488
```

Figure IV.17: Exemple de l'affichage du "Yr".

- **9:** Affichage du l'erreur. Erreur=yd-yr

```
>> erreur=yd-yr

erreur =

   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
   -0.0512
```

Figure IV.18: Exemple de l'affichage du l'erreur

B. Les outils de coupe

On ne peut pas faire la détection parce que le signal obtenu aucun changement d'état de ces valeurs donc une distance nulle entre les valeurs propres.

C. Le turboréacteur

On ne peut pas détecter l'anomalie parce l'orientation de variation de données est très bruités.

7.3 Méthode de Caractéristiques temporelles

A. La Batterie

Nous avons faire l'apprentissage de tous les caractéristiques temporelles et on a trouvé que v_fact_cret est bien précisé où se trouve l'anomalie. Voir la Figure IV.12

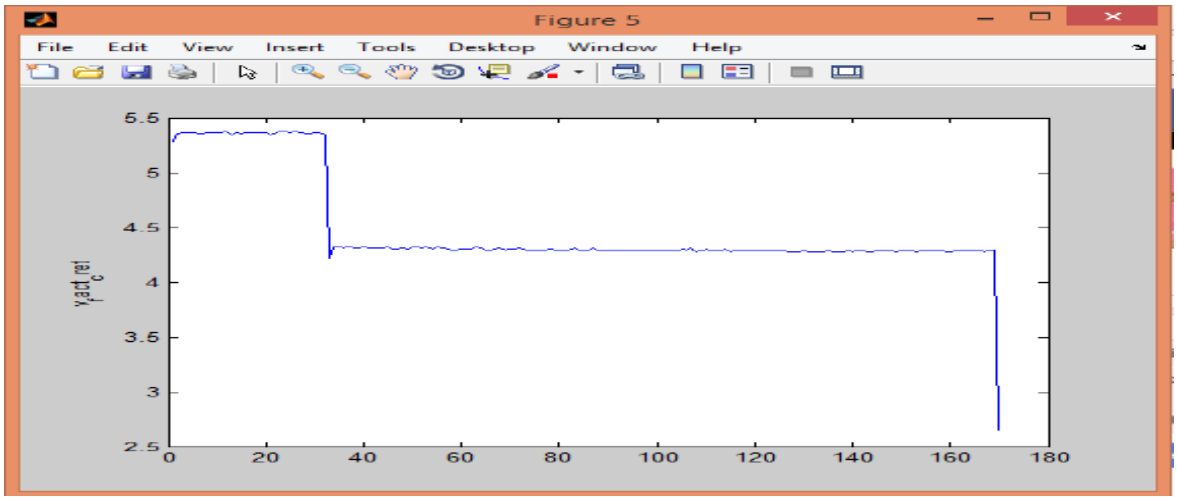


Figure IV.19:v_fact_cret(Batterie)

- **5:** Clique sur "*Train*" pour sortir l'erreur.

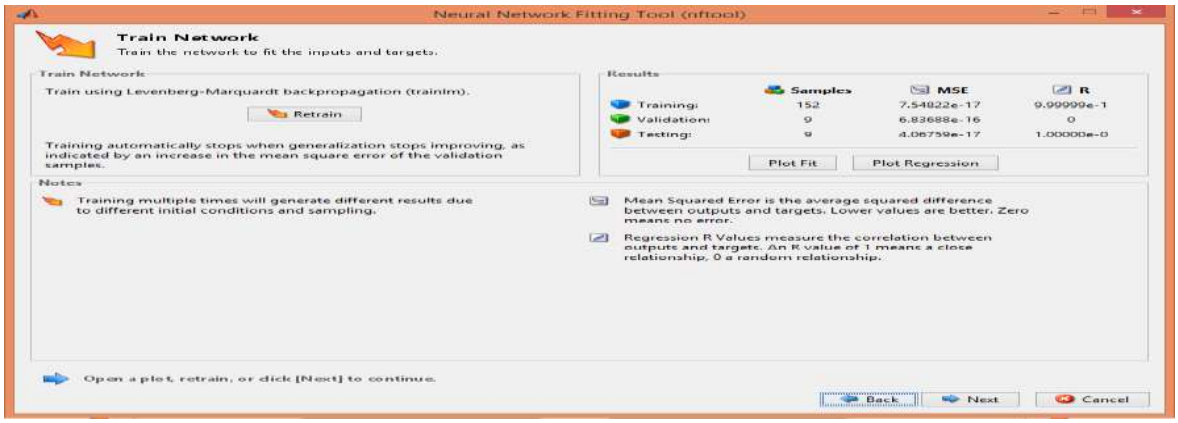


Figure IV.20 : Démarrage de l'apprentissage

- **6:** La fenêtre de Neural Network Training.

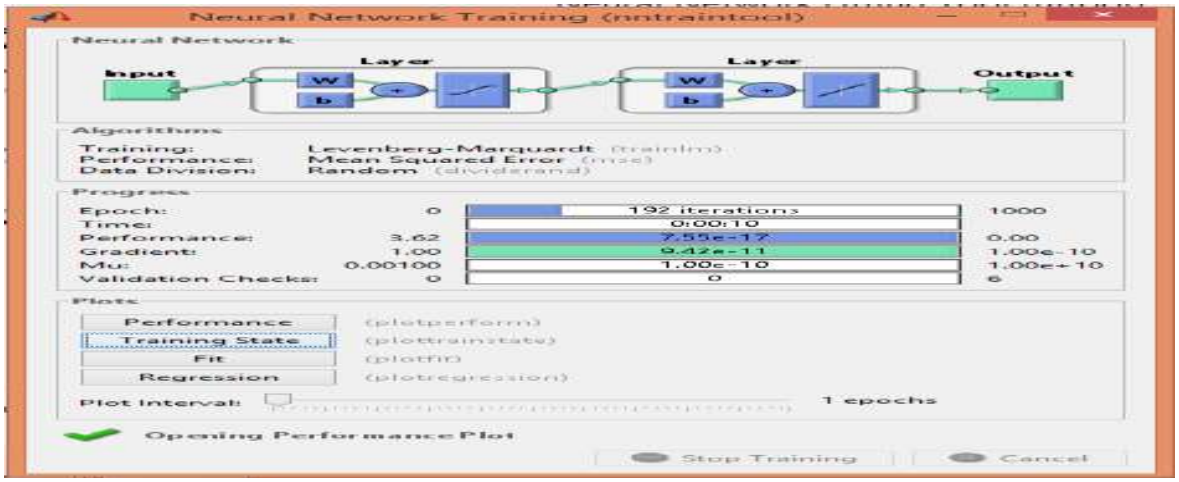


Figure IV.21: Résultat de l'apprentissage.

- **7** : La performance.

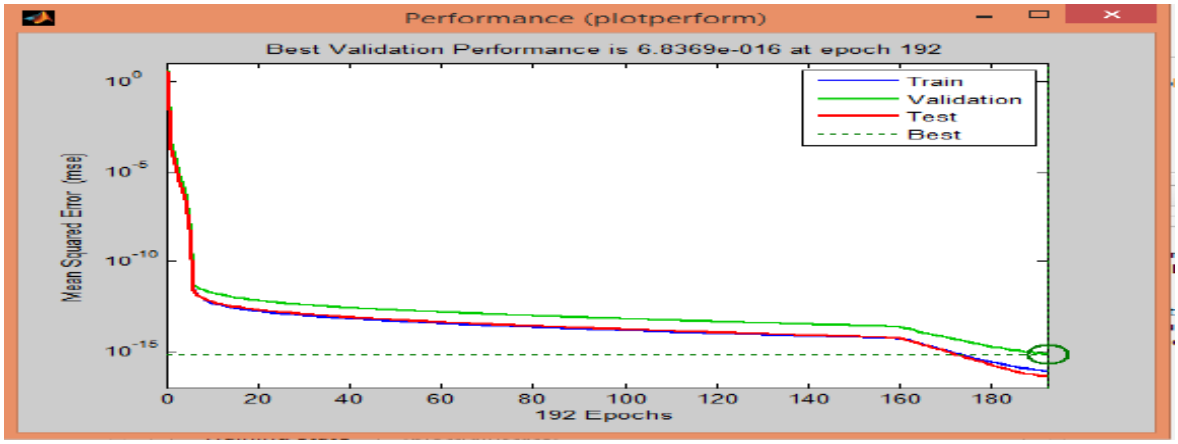


Figure IV.22: Affichage des graphes de performance (MSE).

- **8 :** Affichage de l'Yr :

```
>> yr=sim(net,fact_cret')'

yr =

   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
   -1.0000
```

Figure IV.23: Exemple de l'affichage du "Yr".

- **9** : Affichage du l'erreur :

```
>> errur=d-yr

errur =

   1.0e-007 *

    -0.0005
     0.0002
    -0.0015
    -0.0016
    -0.0005
    -0.0022
    -0.0019
    -0.0007
     0.0002
    -0.0004
    -0.0012
     0.0021
     0.0028
    -0.0015
    -0.0021
    -0.0019
    -0.0004
    -0.0016
    -0.0000
    -0.0014
     0.0047
    -0.0007
```

Figure IV.24: Exemple de l'affichage du l'erreur

B. Les outils de coupes

Même pour **l**es outils de coupes on a travaillé sur NV_rms :

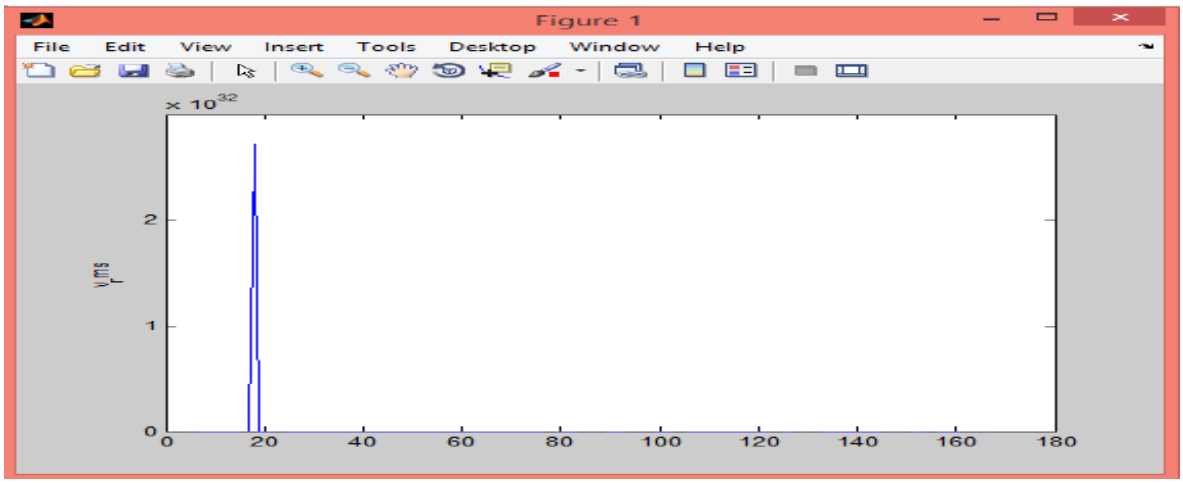


Figure IV.25: RMS

➢ **6:** La fenêtre de Neural Network Training.

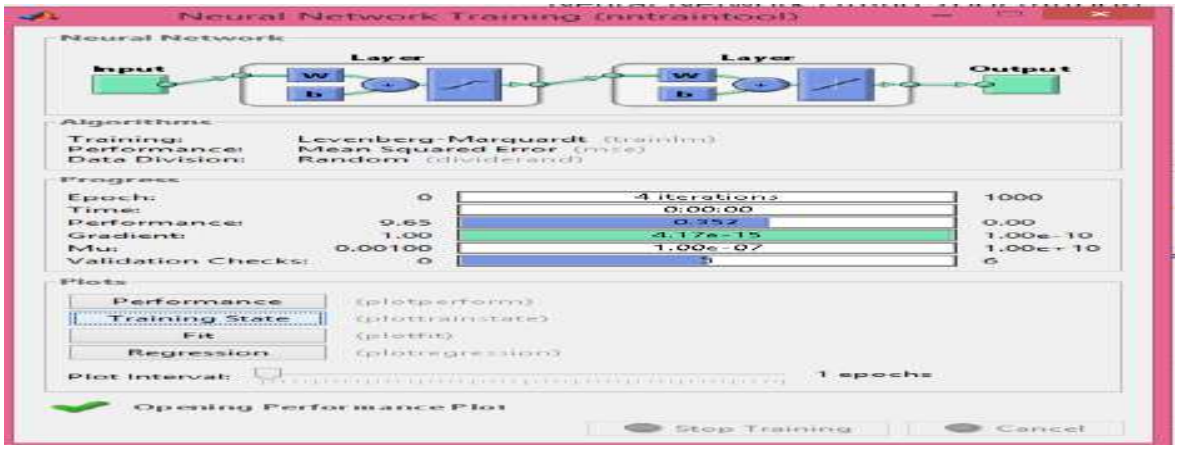


Figure IV.26: Résultat de l'apprentissage.

➢ **7** : La performance.

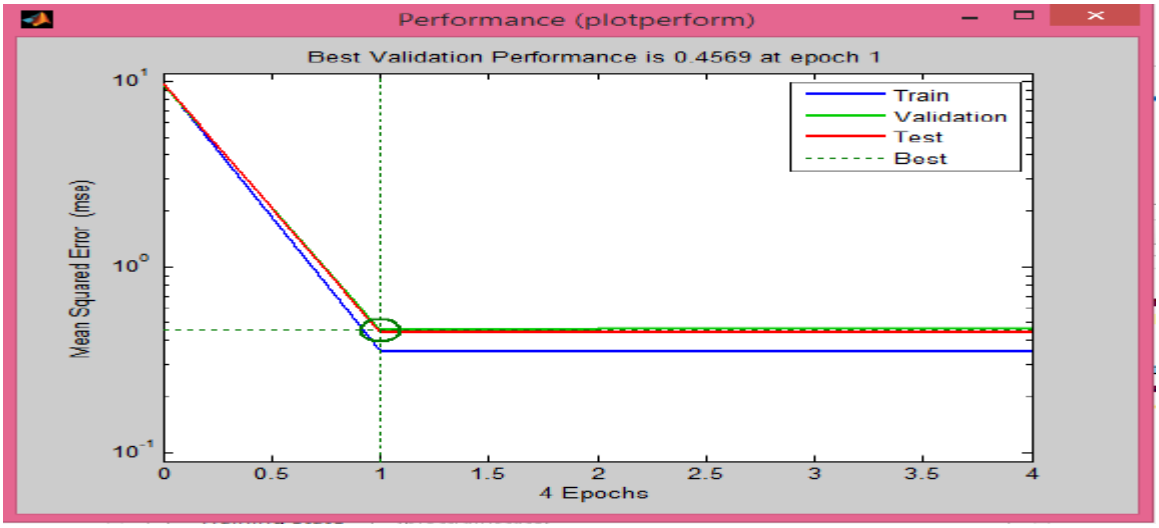


Figure IV.27: Affichage des graphes de performance (MSE).

- **8 :** Affichage de l'Yr :

```
>> yr=sim(net,Nv_rms)'

yr =

    0.8420
    0.6645
    0.6645
    0.8420
    0.6645
    0.8420
    0.8420
    0.8420
    0.8420
    0.8420
    0.8420
    0.8420
    0.8420
    0.8420
    0.8420
    0.6645
    0.8420
    0.9979
    0.8420
    0.8420
    0.8420
    0.8420
    0.6645
    0.8420
    0.8420
    0.8420
```

Figure IV.28: Exemple de l'affichage du "Yr".

- 9 : Affichage de L'erreur :

```
   -1.6645
   -1.8420
    0.0021
    0.1580
    0.1580
    0.1580
    0.1580
    0.3355
    0.1580
    0.1580
    0.1580
    0.1580
    0.1580
    0.1580
    0.1580
```

Figure IV.29: Exemple de l'affichage du l'erreur

C. Le turboréacteur

On ne peut pas faire la classification grâce à détecter l'anomalie

Tableau IV.1 : résumée le résultat

Les données / Les méthodes		Les Batteries	les outils de coupes	Les turboréacteurs
Distance de mesure	p	✓	X	X
	U	✓	X	X
caractéristiques temporelles		✓	✓	X
FFT		X	X	X
Cluster		✓	✓	✓

✓ : donnée un résultat X : aucune résultat

8. Conclusion

Dans ce chapitre on a appliqué la détection par RN sur les différents méthodes testées à partir des descripteurs extraits .a la fin on regrouper les résultats obtenus de notre application dans un tableau qui résume notre recherche.

Conclusion générale

Conclusion générale

Avec les progrès technologiques considérables l'être humain est entouré d'outils, de machines et de systèmes de plus en plus sophistiqués. Cette complexité croissante des systèmes rend la tâche de maintenance plus difficile et son accomplissement implique une grande perte de temps, ce qui imposa le recours à des technologies plus évoluées pour l'exécution de cette tâche.

Pour réaliser une maintenance préventive d'un système, il est nécessaire de surveiller son état de santé afin d'estimer le temps résiduel avant défaillance (RUL) de ses équipements.

Or, l'estimation du RUL impose la détection du début de la dégradation, signée par l'apparition d'une anomalie dans le fonctionnement de l'équipement en question. Cet équipement passe alors d'un état de fonctionnement normal vers un état de fonctionnement anormal.

Les RNs sont une discipline de l'Intelligence Artificielle (l'IA) très utilisés dans les approches guidées par les données du PHM. La classification par RN est fortement dépendante de la qualité des entrées de ce dernier, d'où l'importance de l'extraction des bons caractéristiques à présenté à cette entrée.

Cette tache est plus complexe encore lorsqu'il s'agit d'une approche universelle qui doit fonctionner avec différents type de données capteurs.

Le travail qui a était réalisé concerne la détection des anomalies des systèmes industriels en faisant un suivi de leurs éléments critiques. Le premier point fut d'appliquer différentes méthodes d'extractions de caractéristique et extraire le bon caractéristique qui possède l'information de dégradation. la deuxième point fut faire la détection par le RN où la rentré de RN sont les descripteurs obtenu de chaque méthodes appliquée pour classifier les données en état normal ou dégradé et a la fin conclure la meilleure méthode qui donne la bonne résultat sur quel de type de donnée.

Les principaux résultats rapportés dans ce travail sont :

1 : Nous avons testé différents méthodes sur des données issues de différents type de composant critique pour connaitre le passage de l'état normal à l'état dégradé du système industriels c'est-à-dire le temps de l'apparition de l'anomalie.

2 : Nous allons choisi les bons descripteurs qui sont extrait d'après les résultats des méthodes appliquées qui sont la rentrée de RN.

3: Parmi les résultats obtenus de la détection par le RN avec différents codes de sortie et nombre de neurones dans la couche caché on a pu choisir le bon codage qui est le code (Y=-1,1). D'après les résultats obtenus, la bonne classification correspond au nombre de neurones dont la couche cachée est égale à dix neurones.

4 : d'après la détection par le RN, on a classé les meilleures méthodes dans un tableau qui résume notre recherche.

Toutefois, les données réelles, issues de l'industrie sont souvent très bruitées, incomplètes et concerne non seulement la dégradation lente du l'élément critique, mais aussi les pannes subites. Dans ce cas des tests plus poussés sont nécessaires pour définir un bon système.

Dans notre recherche on a pas trouvé une méthode générique car les méthodes testé ne marche pas sur tous les types de donnée

Notre proposition à la venir pour améliorer cette application, il faut appliquée plusieurs méthodes aux différents données possible puis extraire un algorithme générique applicable à tous ces données repose sur les résultats de ces méthodes.

Deuxième proposition est d'ajouter autre modules ou outils pour dépanner automatiquement le système ou bien l'arrêter.

Références bibliographiques

Références

Chapitre 1

[1] Pauline RIBOT, *«Vers l'intégration diagnostic/pronostic pour la maintenance des systèmes complexes»*, thèse de doctorat en Automatique / Robotique, Université Paul Sabatier,Toulouse III – France, 2009.

[2] Racha Khelif,, « Estimation du RUL par des approches basées sur l'expérience :de la donnée vers la connaissance »,Science de l'ingénieur[physics],Université de Franche-Cpmté,2015.

[3] Kamal Medjaher « *Contribution au pronostic de défaillances guidé par des données* »,Thèse de doctorat en Sciences de l'ingénieur [physics]. Universié de Franche-Comté, 2014.

[4] AFNOR, *«Maintenance - Concepts et définitions des activités de maintenance»*, Norme NF X 60-010, Association Française de Normalisation, 1994.

[5] Fatma-zohra GHERNAOUT et Imene ELOUCHFOUNE, *«Télésurveillance des systèmes industriels»*, thèse de Master en Système Intelligent et Communicants (SIC), Université Dr. Yahya FARES, Médéa – Algérie, 2015.

[6] Ly Fatime,*« Contribution par la surveillance prédictive indirecte à l'optimisation de la maintenance dans les systèmes flexibles de production manufacturière »*, thèse de doctorat en Automatique et Informatique industrielle, Université des Sciences et Technologies de Lille - France, 1999.

[7] M.C. CARNERO, *«Selection of diagnostic techniques and instrumentation in a predictive maintenance program. A case study »*, Decision Support Systems, vol, 38,pp.,539 – 555,2003.

[8] Moussa Amadou TRAORE *«Supervision adaptative et pronostic de défaillance pour la maintenance prévisionnelle de systèmes évolutifs complexes»* thèse de doctorat en Automatique et Informatique Industrielle, Université Lille1 – France, 2011.

[9] Antonio Orantes MOLINA, *« Méthodologie pour le placement des capteurs à base de méthodes de classification en vue du diagnostic »*, Thèse de doctorat en Automatique / Robotique, INSA de Toulouse – France, 2005.

[10] David GUCIK-DERIGNY, *« Contribution au pronostic des système non linéaire à base de modeles théorique en application »*, Thèse en Automatique, Université Paul Cézanne - Aix-Marseille III - France, 2011.

[11] Abdenour SOUALHI, *« Du diagnostic au pronostic de panne des entrainements électriques »*, Thèse de doctorat en Automatique/électronique,Université Glaude Bernard Lyon1- France, 2013.

[12] Löhr, Conor Haines, and Matthias Buderath, «Data Management Backbone for Embedded and PC-basedSystemsUsing OSA-CBM and OSA EAI», First EuropeanConference of the Prognostics and Health Management Society 2012 (PHM-E'12), Dresden, Germany, July 3 - 5, 2012.

[13] Mohamed EL-KOUJOK, *«Contribution au pronostic industriel : intégration de la confiance à un modèle prédictif neuro-flou»*,Thèse de Doctorat en Automatique, Université de Franche-Comté (Ecole Doctorale Sciences Physiques pour l'Ingénieur et Microtechniques), 2010.

[14] Ahmed Mosallam « *Remaininguseful life estimation of critical components based on Bayesianapproaches* »Thèse de doctorat en Engineering Sciences [physics]. Universit´e de Franche-Comté., 2014.

[15] ABDENOUR SOUALHI , « Du diagnostic au pronostic de défaillance guidé par les données »,thèse de doctorat en génie électrique , université Claude Bernard Lyon 1-Lyon1-France,2007.

[16] N Tandon and A Choudhury, "A review of vibration and acousticmeasurementmethods for the detection of defects in rollingelementbearings," Tribology International, vol.32, pp.469 - 480, 1999. B. Li, M.Y. Chow, Y. Tipsuwan, and]. Hung, "Neural network basedmotor.

[17] Lee. Burgess, Terry. Shimbel, "Whatis the prognosis on your maintenance program," Engineering &Miningjournal, May.1995.

[18] W.J. Wang and P.D. McFadden, "Application of wavelets to gearbox vibration signals for faultdetection," journal of Sound and Vibration, vol.192, pp.927 - 939,1996.

[19] Bouthaina ABICHOU, *« Contribution à la formalisation de bilans / états de santé multi-niveaux d'un système pour aider à la prise de décision en maintenance : agrégation d'indicateurs par l'intégrale de Choquet »*,Thèse de doctorat en Sciences de l'ingénieur. Université de Lorraine, 2013.

[20] David Gucik-Derigny, « *Contribution au pronostic des systèmes non linéaires à base de modèles :Théorie et application »*,Thèse de doctorat en Automatique.,Université Paul Cézanne - Aix-Marseille III, 2011.

[21] Abdenour Soualhi,« Du diagnostic et pronostic de panne des entrainements électriques »thèse de doctorat en Automatique , électronique.Université Glaude Bernard liyon1.2013.

Chapitre II

[22] Pauline Ribot « *Vers l'intégration diagnostic/pronostic pour la maintenance des systèmes complexes* »Thèse en Automatique / Robotique . Université Paul Sabatier - Toulouse III, 2009. Français.

[23] Mr. Sekkal Mohamed Chakib Cours Analyse des Données deuxième année SIC. Université DR.YahiaFares de Médéa.

[24] Isabelle Guyon, André Elisseeff, "A*n Introduction to Variable and Feature Selection*", Journal of Machine Learning Research 3 (2003) 1157-1182.

[25] Christopher M. Bishop. Pattern Recognition and Machine Learning. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006

[26] https://ti.arc.nasa.gov/tech/dash/pcoe/prognostic-data-repository/

[27] http://www.tcstec.ch/fr/ibs

[28] NACIB.D, « *Cours fabrication mécanique* »univerisité Kasdi mrbah.Ourgla.2007.

[29] https://fr.wikipedia.org

Chapitre III

[30] Tsirizo RABENORO «*Outils statistiques de traitement d'indicateurs pour le diagnostic et le pronostic des moteurs d'avions*», THÈSE DE DOCTORAT Discipline [Mathématiques appliquées] UNIVERSITÉ PARIS 1 - PANTHÉON SORBONNE 2015

[31] https://leturboreacteur.jimdo.com

[32] BelfarhiNedjoua, « *Conception d'un outil d »aide à la détection et diagnostic des défaillances dans in système de production »*, Travail effectué au sein du Laboratoire d'automatique et productique (U. BATNA) 2011

[33] D. Diallo, M.E.H. Benbouzid « *METHODES DE DETECTION ET DE DIAGNOSTIC DE DEFAUTS DANS LES SYSTEMES ELECTRIQUES* »2007

[34] W. Yan, H. Qiu, and N. Iyer. Feature extraction for bearingprognostics and health management (PHM)-a survey. Technical report, Air Force ResearchLaboratory, 2008

[35] Pierre-louis GONZALEZ, « *methode de classification*»

[36] David Gucik-Derigny « *Contribution au pronostic des systèmes non linéaires à base de modèles :Théorie et application* »,Thèse de doctorat en Automatique. Université Paul Cézanne - Aix-Marseille III ,Français, 2011.

[37] M. Schyns, "*Les réseaux de neurones: principes et application à la détection financière des faillites*",Février 1997

[38] M.SAGASI, « *Application des réseaux de neurone à l'identification d'un axe de machine-outil* », THESE pour obtenir le grade de docteur de L'INPG, 2002.

[39] BENADDA Mahdjouba et ZOUBIR Rania«*Amélioration de la maintenance préventive d'une centrale thermique par l'application des réseaux de neurones artificiels et la logique floue*»thèse de MasterMANAGEMENT ET INGENIERIE DE LA MAINTENANCE INDUSTRIELLE .alger.Dergana. 2016-2017

[40] MERZOUKA Nouressadat,"Etude des performances des réseaux de neurones dynamiques à représenter des systèmes réels : une approche dans l'espace d'état",juil. 2009

[41] M.AMMAR, « *Mise en œuvre de réseaux de neurone pour modélisation de cinétiques réactionnelles en vue de la transposition batch/continu* », THESE présentée pour obtenir le titre de docteur de l'institut national polytechnique de Toulouse, 2007

[42] G.ZWEINGELSTEIN, *« Diagnostic des défaillances; théories et pratique pour les systèmes industriels* », col. Traite des nouvelles technologies, séries diagnostic et Maintenance, hermès ,1995.

[43] Mr AMRANI Mohamed, "*Surveillance et diagnostic d'une ligne de production par les réseaux de neurones artificiels*", Université M'hamed Bougara – Boumerdes, Année 2010

[44] A.ASSOM, « *étude de la tolérance aux aléas logique des réseaux de neurone artificiel* », THESE de doctorat, institut national poly technique de Grenoble France, 1997