République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieuret de la Recherche Scientifique

**Université YAHIA FARES DE MEDEA**



**Faculté des Sciences et de la Technologie**

**Département de Génie de la Matière**

Mémoire de fin d'études pour l'obtention du diplôme de Master

En **Génie Mécanique**

Option : **Mécatronique**

**THEME**

# Diagnostic des défauts de roulement par les réseaux de neurones

**Dirigé par** :
Dr. BOUMAHDI Mouloud

**Etudié par** :
M^elle^THAMERI Hadda

Promotion **2013 /2014.**

# *Dédicaces*

*A la mémoire de* ***mon Père***

*Ce travail est le fruit de tes sacrifices que tu as*

*Consentis pour mon éducation et ma formation*
*A la lumière de mes jours, la source de mes efforts, la flamme de*
*mon cœur, ma vie et mon bonheur,* ***maman*** *que j'adore.*

*Aux personnes dont j'ai bien aimé la présence dans ce jour,*
*A tous mes* ***frères Naser, Faisal*** *et sa fille* ***Sirine***
*et ma* ***sœur, Imene*** *et son marie et son fils* ***Younes***
*A toute ma famille, je dédie ce travail*
*dont le grand plaisir leurs revient en premier lieu pour*
*leurs conseils, aides, et encouragements.*
*Je fais une dédicace très spéciale à mon frère* ***Mohamed***
*pour leur soutien moral, Leur gentillesse*
*et leur profond attachement m'ont permis de réussir mon*
*Travail. et que ce travail soit témoignage de ma reconnaissance et de*

***mon amour*** *sincère.*

*Aux personnes qui m'ont toujours aidé et encouragé, qui étaient*
*toujours à mes côtés, et qui m'ont accompagnaient durant mon*
*chemin d'études, mes aimables amis, collègues d'étude,*
*Salima ,Hayet, Sihem, Randa, Asma, Rima, Nassima, Monira, Souad, Zineb.*

*Á Toutes la promotion de mécatronique*

*«LMD »2013-2014*

# Remerciement

Avant tout, l'ouvrage dédier à ***ALLAH ,*** *notre créateur et maitre de l'univers de toutes ses bontés, d'avoir envoyer à nous le prophète* **MOHAMED** qui est notre premier éducateur puis de m'avoir donné tout, du courage pour finir ce travail de recherche.

Je tiens à exprimer une profonde reconnaissance à mon Promoteur Dr. **BOU**MEHDI Mouloud pour ses conseils et son soutient

Je remercie chaleureusement et particulièrement Dr. **KHAOUANE Latifa**, qui m'a guidé avec grande patience tout au long de l'élaboration de ce travail et pour ses aides précieuses qui ont judicieusement éclairé mon chemin vers l'aboutissement et la réussite de la concrétisation de mon mémoire

Je tiens particulièrement à exprimer, à travers ces quelques lignes, toute ma gratitude et mon profond respect a Pr. HANINI Salah pour son suivi et aide

Je ne saurais présenter ce travail sans exprimer mes vifs remerciements à Melle CHENNOUF Salima enseignante pour m'avoir longuement soutenu et aidé sans relâche nonobstant leur tache journalière sans répit.

Mes vifs remerciement aux membres du jury d'avoir accepté de juger mon travail.

Mes remerciements fidèles et reconnaissants rejoignent à tous ceux qui de prêt ou de loin, en répondant volontiers à mes questions, voir mes tracasseries nous ont aidés à l'élaboration de ce document.

Mes vives remerciement à mes chers parents qui ravaient de ma voire le pied à l'étrier sans oublier mes collègues qui par leur suggestions et leur attitude à la fois pleine d'humour et de sérieux ont énormément facilite mon travail.

# Sommaire

| SOMMAIRE | Page |
|---|---|
| **INTRODUCTION GENERALE** | **1** |
| **CHAPITRE I : LES RESEAUX DE NEURONES ARTIFICIELS** | |
| I.1. Introduction | **2** |
| I.2. L'intelligence artificielle | **2** |
| I.2.1 Définition | 2 |
| I.2.2 Domaines de l'intelligence Artificielle | 3 |
| I.2.3 Les modèles de l'intelligence artificielle | 4 |
| I.3 Réseaux de neurones | **4** |
| I.3.1 Introduction aux réseaux de neurones | 4 |
| I.3.2 Définition | 4 |
| I.3.3 Historique | 5 |
| I.3.4 Applications des réseaux de neurones | 5 |
| I.3.5 Notions fondamentales sur les réseaux de neurones artificiels | 6 |
| I.3.5.1 Analogie entre neurone biologique et neurone artificiel | 6 |
| I.3.6 Le modèle mathématique d'un neurone artificiel | 9 |
| I.3.7 Fonction d'activation | 11 |
| I.3.8 Architecture des réseaux | 14 |
| I.3.9 Apprentissage | 16 |
| I.3.9.1 comment apprendre au réseau | 16 |
| I.3.9.2 Surapprentissage | 17 |
| I.3.9.3 Rétropropagation | 18 |
| I.3.9.4 Élagage | 18 |
| I.3.9.5 Précision | 18 |
| I.4 Conclusion | 18 |
| **CHAPITRE II : MAINTENANCE DES MACHINES TOURNANTES** | |
| II.1. Introduction | 19 |
| II.2.Machines tournantes | 19 |
| II.3.Maintenance des machines tournantes | 20 |
| II.4. Méthode de surveillance des machines | 22 |
| II.4.1. Surveillance traditionnelle | 22 |
| II.4.2.Surveillance par analyse de lubrifiant | 23 |
| II.5.Analyse des vibrations | 24 |
| II.5.1.Amplitude d'un signal vibratoire | 24 |
| II.6.Les différents défauts du diagnostic des machines tournantes | 26 |
| II.7 Les roulements | 27 |
| II.8.Modes de défauts de roulement | 29 |
| II.8.1.La fatigue | 29 |
| II.8.2.L'usure (The wear) | 30 |
| II.8.3.La corrosion | 30 |
| II.8.4.Le faux brinellage | 30 |
| II.8.5.L'absence de lubrification | 31 |

| | |
|---|---|
| II.9.Processus de dégradation d'un roulement | 33 |
| II.10.Analyse vibratoire des défauts de roulements | 34 |
| II.11.Détection des défauts | 34 |
| II.11.1.La valeur efficace du signal *(ou RMS Root Mean Square)* | 34 |
| II.11.2.Les indicateurs crêtes | 35 |
| II.11.3.Le Kurtosis | 37 |
| II.12.Fréquences caractéristiques des défauts de roulement | 37 |
| II.13.Niveaux globaux spécifiques aux roulements | 39 |
| II.14.Conclusion | 40 |
| **CHAPITRE III : L'ETUDE EXPERIMENTALE** | |
| III.1. Introduction | 41 |
| III.2. Méthodologie de modélisation | 41 |
| III.2.1. collecte des données | 41 |
| III.2.2. Sélection des entrées et des sorties du modèle neuronale | 43 |
| III.2.3. normalisation de la base de données partielle | 43 |
| III.2.4. mise en forme des données | 44 |
| III.2.5. conception et optimisation | 44 |
| III.3.les étapes de l'exécution pour trouver le modèle mathématique | 44 |
| III.3.1. Le choix de neurone optimal | 45 |
| III.3.1.1 Structure Du RNSO Obtenu pour le 4$^{ème}$ neurone de la couche cachée (net4_7) | 45 |
| III.3.1.2 l'algorithme d'apprentissage et la fonction d'activation | 46 |
| III.3.1.3 expressions mathématique des modèles neuronaux optimisés | 47 |
| III.3.1.4 Performance du réseau de neurone en termes de pourcentage de classification | 48 |
| III.3.1.5 Evaluation des performances du modèle par la matrice de confusion pour le 4$^{ème}$ neurone | 50 |
| III.4. Validation des résultats obtenus par RNA avec les valeurs expérimentale | 51 |
| III.4.1 Prévision d'une classe | 52 |
| III.4.1.1 Test du modèle | 52 |
| III.4.1.2 Structure Du RNSO Obtenu pour le 5$^{ème}$ neurone (net 5_8) | 53 |
| III.4.1.3 Expressions mathématique des modèles neuronaux optimisés | 54 |
| III.4.1.4 Performance du réseau de neurone en termes de pourcentage de classification | 56 |
| III.4.1.5 Interprétation des graphes | 58 |
| III.4.1.6 Validation des résultats obtenus par RNA avec les valeurs expérimentale | 59 |
| III.5.Conclusion | 59 |
| **Conclusion générale** | **60** |
| **Référence bibliographique** | **62** |
| **Annexe** | **65** |

## Résumé

Différentes méthodes sont mise en œuvre pour suivre l'état des défauts rencontrés sur une machine tournante, elles différent entre elles par leur précision, leur simplicité de mise en œuvre et leur cout. Dans cette étude, une méthode basée sur les réseaux de neurones est proposée pour modéliser le processus de détection des défauts de roulement.Notre première contribution a apporté sur l'utilisation des réseaux de neurones artificiels de types perceptron multicouche. Le développement de cette approche a été fondé sur trois étapes : préparation de la base des données, optimisation des paramètres pertinents de l'architecture du réseau de neurones puis le teste de généralisation et d'interpolation de réseau de neurone statique optimisé(RNSO). Le RNSO obtenu durant cette contribution comporte une couche cachée avec une architecture de :{3-4-1} et les valeurs des erreurs MSE et SSE sont acceptable.Notre deuxième contribution a apporté sur la prévision d'une classe afin de tester le modèle neuronale obtenu. En conséquence les réseaux de neurones peuvent être utilisés avec succès dans la modélisation de processus de détections des défauts de roulement.

## ملخص

لتتبع حالة العيوب التي تواجه الآلات الدوارة يتم تطبيق أساليب مختلفة و هي تختلف فيما بينها من حيث دقتها، بساطة تنفيذها وتكلفتها. في هذه الدراسة، تم اقتراح طريقة تقوم على الشبكات العصبية لنمذجة عملية الكشف عن عيوب في المتدحرجات. مساهمتنا الأولى تتمثل في استخدام الشبكات العصبية الاصطناعية من نوع المستقبلات متعدد الطبقات. وقد استند تطوير هذه الشبكة على ثلاث خطوات: إعداد البيانات، والتحسين من المعلومات ذات الصلة بهندسة الشبكة العصبية والاختبارات لتعميم شبكة الخلايا العصبية المستقرة (RNSO). إن الشبكة RNSO تم الحصول عليها من خلال هذه المساهمة تتكون من طبقة خفية ذات هندسة {3-4-1} كمأن قيم الأخطاء MSE و SSE مقبولة. مساهمتنا الثانية تتمثل في التنبؤ حول فئة من أجل اختبار نموذج العصبية المتحصل عليه. وفي الأخير، فإن الشبكات العصبية يمكن استخدامها بنجاح في عملية نمذجة انظام كشف عيوب المتدحرجات.

## Abstract

Different methods are implemented to monitor the status of defects encountered on a rotating machine, they differ from each other by their accuracy, simplicity of implementation and their cost. In this study, a method based on neural networks is proposed to model the process of detection of the ball bearing defect. First contribution was givenon the use of artificial neural networks type multilayer perceptron. The development of this approach was based on three steps: preparation of the data, optimization of the relevant parameters of the neural network and the tests of generalization and interpolation of the static neural network optimized (RNSO). The RNSO obtained during this contribution has a hidden layer with architecture: {3-4-1} and the values of MSE and SSE errors are acceptable. Our second contribution provided on the prediction of a class to test the neural model obtained. Consequently, the neural networks can bused with success in the modeling of the defects detections process.

# Liste des figures


| Figure | Titre de la figure | page |
|---|---|---|
| **Figure I.1** | Schéma complet d'un neurone biologie | 7 |
| **Figure I.2** | Représentation d'un neurone formel | 8 |
| **Figure I.3** | Schéma de comparaison entre un neurone biologique et un neurone artificiel | 9 |
| **Figure I.4** | Modèle mathématique du neurone artificiel | 10 |
| **Figure I-5** | Modèle mathématique du neurone artificiel | 11 |
| **Figure I.6** | Architecture générale d'un RNA | 14 |
| **Figure I.7** | Réseau Monocouche | 14 |
| **Figure I.8** | Réseau Multicouche | 15 |
| **Figure I.9** | Réseau à connexions complètes | 15 |
| **Figure I.10** | Réseau à connexions locales | 16 |
| **Figure I.11** | Schéma représentatif d'un apprentissage supervisé | 16 |
| **Figure I.12** | Schéma représentatif d'un apprentissage non supervisé | 16 |
| **Figure I.13** | apprentissage du réseau | 17 |
| **Figure II.1** | machine tournante | 19 |
| **Figure II.2** | Différents types de maintenance | 20 |
| **Figure II.3** | Maintenance corrective | 20 |
| **Figure II.4** | Maintenance systématique | 21 |
| **Figure II.5** | Maintenance préventive conditionnelle | 21 |
| **Figure II.6** | Méthodes de surveillance des machines | 22 |

| | | |
|---|---|---|
| **Figure II.7** | Amplitude de signale vibratoire | 25 |
| **Figure II.8** | Défauts réels de roulements réparti et localisé | 27 |
| **Figure II.9** | Défaut de bille et un écaillage de la bague interne | 31 |
| **Figure II.10** | Mode de détection de défaut de roulement | 32 |
| **Figure II.11** | Image vibratoire d'un défaut de la bague externe | 32 |
| **Figure II.12** | Image vibratoire d'un défaut de la bague interne | 33 |
| **Figure II.13** | Dégradation d'un roulement | 33 |
| **Figure II.14** | Evolution du facteur de crête en fonction d'un défaut écaillage sur un roulement | 36 |
| **Figure II.15** | Représentation schématique du Kurtosis. | 37 |
| **Figure II.16** | Caractéristiques d'un roulement | 38 |
| **Figure II.17** | Roulement neuf | 39 |
| **Figure II.18** | le trou de pitting apparait | 39 |
| **Figure II.19** | le trou de pitting se développe | 39 |
| **Figure II.20** | les trous de pitting se multiplient | 40 |
| **Figure II.21** | le roulement est hors service | 40 |
| **Figure III.1** | Banc d'essai | 42 |
| **Figure III.2** | Schéma simplifié de l'architecture du RNSO | 46 |
| **Figure III.3** | Représentation schématique du RNS optimisé | 47 |
| **Figure III.4** | Performance du réseau de neurone en termes de pourcentage de classification | 48 |
| **Figure III.5** | Performance du réseau de neurone en termes de pourcentage de classification pour la base de validation | 49 |

| | | |
|---|---|---|
| **Figure III.6** | Performance du réseau de neurone en termes de pourcentage de classification pour la base de teste | 49 |
| **Figure III.7** | Performance du réseau de neurone en termes de pourcentage de classification pour toute la base | 50 |
| **Figure III.8** | Schéma simplifié de l'architecture du RNSO | 53 |
| **Figure III.9** | Représentation schématique du RN*S* optimisé (net 5_8) | 54 |
| **Figure III.10** | Performance du réseau de neurone en termes de pourcentage de classification pour la base d'apprentissage | 56 |
| **Figure III.11** | Performance du réseau de neurone en termes de pourcentage de classification pour la base de validation | 56 |
| **Figure III.12** | Performance du réseau de neurone en termes de pourcentage de classification pour la base de teste | 57 |
| **Figure III.13** | Performance du réseau de neurone en termes de pourcentage de classification pour toute la base | 57 |

# Liste des tableaux


| | | |
|---|---|---|
| **Chapitre I. RNA** | | |
| **Tableau I.1.** | **.** Analogie entre le neurone biologique et le neurone formel | 8 |
| **Tableau I.2.** | **.** Les fonctions de transfert les plus courantes | 12 |
| **Chapitre III.** ***Modélisation et prévision neuronale du défaut de roulement*** | | |
| **Tableau III.1** | Données accueillies | 42 |
| **Tableau III.2** | Le choix de neurone optimal | 45 |
| **Tableau III.3** | Structure des RNSO utilisés pour la modélisation des défauts. | 46 |
| **Tableau III.4** | Poids et biais du RNS optimal | 48 |
| **Tableau III.5** | Matrice de confusion | 50 |
| **Tableau III.6** | Validation des résultats obtenus par RNA avec les valeurs expérimentale | 51 |
| **Tableau III.7** | prévision des clases | 52 |
| **Tableau III.8** | Structure des RNSO utilisés pour la modélisation des défauts. | 53 |
| **Tableau III.9** | Poids et biais du RNS optimal | 55 |
| **Tableau III.10** | Validation des résultats obtenus par RNA avec les valeurs expérimentale | 59 |

# Nomenclature

| | |
|---|---|
| $Acc_{eff}$ | L'accélération efficace |
| $A_{eff}$ | L'amplitude efficace$A_{eff}$ |
| $d$ | Le diamètre primitif |
| $D$ | Le diamètre des éléments roulants |
| $f_e$ | Défaut d'élément roulant. |
| $f_c$ | Défaut de cage. |
| $fr$ | fréquence de rotation de l'arbre, |
| $f_{rot}$ | la fréquence de rotation de la bague interne (la bague externe étant supposé fixe) |
| $M_4$, $M_2$ | les moments statistiques |
| N | le nombre d'échantillons prélevés dans le signal. |
| $N_b$ | Le nombre d'éléments roulants (billes, rouleaux ou aiguilles) |
| T | Période |
| $\bar{x}$ | La valeur moyenne des amplitudes, |
| $x_i$ | l'amplitude du signal pour l'échantillon i |
| $\alpha$ | L'angle de contact. |
| $\beta$ | angle de contact. |
| $\square_{bille}$ | diamètre des éléments roulants |
| $\square_{moyen}$ | diamètre moyen d'évolution des éléments roulants, |

# Abréviation

| Abréviation | Signification |
|---|---|
| **AC** | **A**mplitude **C**rête |
| **ACC** | **A**mplitude **C**rête à **C**rête |
| **BPFI** | **D**éfaut de **B**ague **I**ntérieure |
| **BPFO** | **D**éfaut de **B**ague **E**xtérieure |
| **FC** | **F**acteur de **C**rête |
| **IA** | **I**ntelligence **A**rtificielle |
| **MSE** | **M**ean **S**quared **E**rror |
| **OBD** | **O**ptimal **B**rain **D**amage |
| **OBS** | **O**ptimal **B**rain **S**urgeon |
| **RMS** | **R**oot **M**ean **S**quare |
| **RNA** | **R**éseau de **N**eurone **A**rtificiel |
| **RNSO** | **R**éseau de **N** eurone **S**tatique **O**ptimal |
| **SSE** | **S**um **S**quared **E**rror |
| **TANSIG** | **F**onction **T**angente **S**igmoïde |
| **TRAINLM** | **L**evenberg-**M**arquardt |
| **VC** | **V**aleur **C**rête |
| **ROC** | **R**eceiver **O**perating **C**haracteristic |

# Introduction générale

# INTRODUCTION GENERALE

L’utilisation continue des machines tournantes dans l'industriel impose l'application d'une stratégie de surveillance, de maintenance et de réparation qui permet d'assurer la sécurité et d'éviter les dégradations importantes.

En fonctionnement, les machines tournantes produisent des vibrations, si l'amplitude de la vibration (déplacement, vitesse ou accélération) dépasse des valeurs proposées pour le bon fonctionnement de la machine, le système de surveillance doit déclencher une alarme ou l'arrêt de la machine.

La maintenance des machines tournantes s'appuie sur la surveillance par analyse vibratoire qui représente un outil indispensable pour la réalisation d'un diagnostic approprié des défauts dans le but de réduire le coût de maintenance, augmenter la disponibilité des équipements, fiabiliser l'outil de production et planifier les interventions qu'au bon moment et pendant des arrêts programmés. D’autres techniques sont aussi utilisées telles que; l’émission acoustique, l'analyse d'huile, les approches de L'intelligence artificiels telles que les réseaux de neurones, la méthode de reconnaissance de forme, etc.

Dans le cadre de cette étude, notre objectif à atteindre est de modéliser le processus de détections des défauts de roulement, élément essentiel dans la construction des machines tournantes et est très sensible à la dégradation, par l'approche réseaux de neurones.

Le chapitre I expose les aspects généraux sur les réseaux de neurones artificiels : définition, historique, les neurones biologiques,Neurone formel, Architecture et les différents modèles de réseaux de neurones.

Le chapitre II présente des notions générales sur le diagnostic des machines tournantes. Plusieurs types de défauts rencontrés dans les machines tournantes ainsi que leurs causes ont été décrits.

Le chapitre III traite l'application de l'approche des réseaux de neurones pour la détection des défauts de roulements.

On clôture le mémoire par une conclusion générale en faisant ressortir les principaux résultats de cette étude et trace les perspectives qui pourront être envisagées pour le futur.

# Chapitre I
# Les réseaux de neurones artificiels

# Chapitre 1: Les réseaux de neurones artificiels

## I.1. Introduction

L'intelligence humaine est une faculté remarquable qui nous permet d'exercer de multiples activités dites cognitives, Comme apprendre, comprendre, évaluer, critiquer, juger, connaître, planifier, analyser, choisir, mémoriser et communiquer. Il est passionnant d'essayer de décrire ces mécanismes, de les comprendre et éventuellement de les simuler. L'intelligence artificielle (IA) s'intéresse à la fois aux descriptions abstraites de 1'intelligence humaine et à la possibilité de réaliser des systèmes artificiels dont le comportement correspondent à ces descriptions.

Les réseaux de neurones artificiels (RNA) sont l'un de ces systèmes, malgré qu'il soit loin de pratiquer les fonctions d'un cerveau humain, mais il arrive à achever d'une manière non complète certaine de ces fonctions. L'utilisation des réseaux de neurones artificiels s'est développée dans de nombreuses disciplines (mécanique, Sciences économiques, environnement, biologie et médecine…).

Les réseaux de neurones artificiels sont notamment appliqués pour résoudre des problèmes de classification, de prédiction, de catégorisation, d'optimisation et de reconnaissance des formes. Les réseaux de neurones constituent en fait un courant bien précis de l'intelligence artificielle, dont le modèle de développement est basé sur l'idée de calquer des algorithmes d'apprentissage sur un modèle simplifié du cerveau.

Dans ce chapitre, on va présenter la description abstraite et le fonctionnement d'un neurone artificiel.

## I.2. L'intelligence artificielle

### I.2.1. Définition

Un système d'intelligence artificielle a pour but la modélisation du comportement d'un expert humain, accomplissant une tâche de résolution des problèmes pour laquelle on ne dispose d'aucun algorithme et ce dans un domaine bien précis

Il existe un certain nombre de définitions différentes de l'IA. On cite entre autres :

- ✓ Système qui pense comme les hommes.
- ✓ Système qui agit comme les hommes.
- ✓ Système qui pense rationnellement.
- ✓ Système qui agit rationnellement**.**

### I.2.2 Domaines de l'intelligence Artificielle

- **Tâches routinières**

  - ✓ Perception : – Vision
    – Parole

- **Langage naturel :** – Compréhension
  – Génération
  – Traduction
  - ✓ Sens commun
  - ✓ Robotique

- **Tâches formelles :**

  - ✓ Jeux : – Échecs
    – Backgammon
    – Dames
  - ✓ Mathématiques : – Géométrie
    – Logique
    – Calcul intégral
    – Preuves de théorèmes

- **Systèmes experts**

  - ✓ Ingénierie : – Conception
    – Réparation, déverminage
    – Planification industrielle
  - ✓ Analyse scientifique
  - ✓ Diagnostic médical
  - ✓ Analyse financière

- **Réseaux de neurones artificiels**

  - ✓ Classification
  - ✓ Apprentissage supervisé et non-supervisé : – Perceptron multicouche
    – Réseaux auto-organisés
    – Simulations biologiques
  - ✓ Imagerie et reconnaissance de formes **[6].**

### I.2.3 Les modèles de l'intelligence artificielle

Il existe plusieurs modèles utilisables, parmi eux on cite :

- Les réseaux neuronaux artificiels
- Calcul évolutionnistes
- Intelligence D'Essaim
- Systèmes immunitaires Artificiels
- Systèmes Brouillés

Le modèle le plus utilisé dans les années précédentes est le réseau de neurone **[7].**

## I.3 Réseaux de neurones

### I.3.1 Introduction aux réseaux de neurones

Les réseaux de neurones ont d'abord été développés pour résoudre des problèmes de contrôle,de reconnaissance de formes ou de mots, de décision, de mémorisation comme une alternativeà l'intelligence artificielle, et en relation plus ou moins étroite avec la modélisation deprocessus cognitifs (capable de connaître ou faire connaître) réels et des réseaux de neurones biologiques **[8].**

### I.3.2 Définition

Les réseaux de neurones sont composés d'éléments simples (ou neurones) fonctionnant en parallèle. Ces éléments ont été fortement inspirés par le système nerveux biologique. Comme dans la nature, le fonctionnement du réseau (de neurone) est fortement influencé par la connections des éléments entre eux. On peut entraîner un réseau de neurone pour une tâche spécifique (reconnaissance de caractères par exemple) en ajustant les valeurs des connections (ou poids) entre les éléments (neurone) **[9].**

### I.3.3 Historique

À l'ère de la cybernétique, l'objectif des chercheurs était de construire une machine capable de reproduire certains aspects de l'intelligence humaine. Mac Culloch et Pitts ont proposé dès 1943 les premiers neurones formels calqués sur les neurones biologiques. Les réseaux de neurones artificiels réalisés à partir du modèle biologique ne sont rien qu'une tentative de modélisation mathématique du cerveau humain. Ils sont donc conçus pour reproduire certaines de leurs caractéristiques comme :

- la capacité d'apprentissage
- la capacité de mémoriser l'information
- la capacité de traiter des informations incomplètes

Les réseaux de neurones ont donc une histoire relativement jeune (60 ans) mais les applications intéressantes des réseaux de neurones n'ont vu le jour qu'il y a une trentaine d'années avec le développement de l'informatique. En effet, ce n'est que depuis le début des années 1990 que les réseaux de neurone artificiels, généralement utilisés en physique, font leur entrée en management en tant que méthode quantitative de prévisions à côté des méthodes statistiques classiques. Les réseaux de neurones artificiels sont particulièrement utilisés en finance mais également dans d'autres domaines de gestion.

Il existe deux raisons principales pour lesquelles les chercheurs en sciences de gestion se sont intéressé aux réseaux de neurones artificiels :

- À l'inverse des méthodes statistiques classiques, les réseaux de neurones artificiels ne nécessitent aucune hypothèse sur les variables.
- Les réseaux de neurones artificiels sont parfaitement adaptés pour traiter des problèmes complexes non structurés (problèmes sur lesquels il est impossible de définir la relation entre les variables utilisées). **[10]**

### I.3.4 Applications des réseaux de neurones

L'étude des réseaux de neurones est une voie prometteuse de l'Intelligence Artificielle, qui a des applications dans de nombreux domaines :

• Aérospatial : pilotage automatique, simulation du vol…

• Automobile : système de guidage automatique,…

• Défense : guidage de missile, suivi de cible, reconnaissance du visage, radar, sonar, lidar, traitement du signal, compression de données, suppression du bruit…

• Electronique : prédiction de la séquence d'un code, vision machine, synthétiseur vocal, modèle

non linéaire,…

• Finance : Prévision du coût de la vie

• Secteur médical : Analyse EEC et ECG

• Télécommunications : Compression de données … **[9].**

### I.3.5 Notions fondamentales sur les réseaux de neurones artificiels

#### I.3.5.1 Analogie entre neurone biologique et neurone artificiel

L'idée de réseau de neurones artificiels a été inspirée de la manière par laquelleles neurones biologiques traitent les informations. Ce concept est utilisé pour mettre en œuvre des logiciels de simulations des processus massivement parallèles qui impliquent des éléments de traitement connectés dans une architecture de réseau. L'apprentissage dans le cerveau humain se fait à travers un réseau des neurones qui sont connectés par l'axone, les synapses et des dendrites **[11].**

❖ **Neurone biologique**

En biologie, un neurone est une cellule nerveuse dont la fonction est de transmettre un signal électriquedans certaines conditions. Il agit comme un relai entre une couche de neurones et celle qui la suit.

Le corps d'un neurone (figure I.1) est relié d'une part à un ensemble de dendrites (entrées du neurone) et d'autre part à un axone, partie étirée de la cellule, qui représentera pour nous sa sortie. Le neurone étudié est connecté aux neurones environnants : il reçoit au niveau de ses dendrites les signaux électriques des neurones "en amont", propagés par les axones de ces derniers. Les charges électriques s'accumulent dans le neurone jusqu'à dépasser un certain seuil : à ce moment la transmission du signal électrique se déclenchevia son axone vers d'autres neurones "en aval".

On remarque que les liaisons axone/dendrite entre deux neurones (connexions synaptiques) ne sont pas toutes de la même efficacité. Ainsi l'entrée associée à une certaine dendrite du neurone pourra avoir plus d'influence qu'une autre sur la valeur de sortie. On peut représenter la qualité de la liaison par un poids, sorte de coefficient s'appliquant au

signal d'entrée. Le poids sera d'autant plus grand que la liaison est bonne. Un poids négatif aura tendance à inhiber une entrée, tandis qu'un poids positif viendra l'accentuer.

La structure d'un neurone se compose de trois parties :

- ***La somma*** : ou cellule d'activité nerveuse, au centre du neurone.
- ***L'axone*** : attaché au somma qui est électriquement actif, ce dernier conduitl'impulsion conduite par le neurone.
- ***Dendrites*** : électriquement passives, elles reçoivent les impulsions d'autresneurones **[19].**

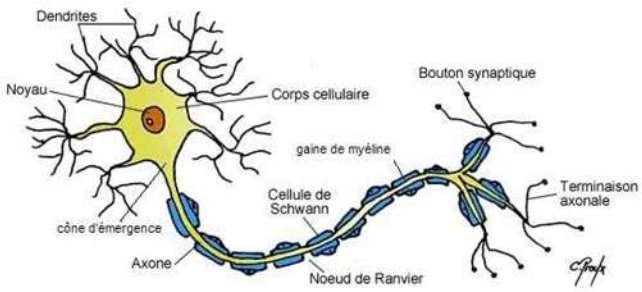



**Figure I.1.** Schéma complet d'un neurone biologie **[12].**

❖ **Le neurone formel (artificiel)**

Un neurone formel est une représentation mathématique et informatique d'un neurone biologique. Le neurone formel possède généralement plusieurs entrées et une sortie qui correspondent respectivement aux dendrites et au cône d'émergence du neurone biologique (point de départ de l'axone). Les actions excitatrices et inhibitrices des synapses sont représentées, la plupart du temps, par des coefficients numériques (les poids synaptiques) associés aux entrées. Les valeurs numériques de ces coefficients sont ajustées dans une phase d'apprentissage. Dans sa version la plus simple, un neurone formel calcule la somme pondérée des entrées reçues, puis applique à cette valeur une fonction d'activation, généralement non linéaire. La valeur finale obtenue est la sortie du neurone

Le neurone formel ( figure I.2) est l'unité élémentaire des réseaux de neurones artificiels dans lesquels il est associé à ses semblables pour calculer des fonctions arbitrairement complexes, utilisées pour diverses applications en intelligence artificielle

**[13].** Mathématiquement, le neurone formel est une fonction à plusieurs variables et à valeurs réelles.

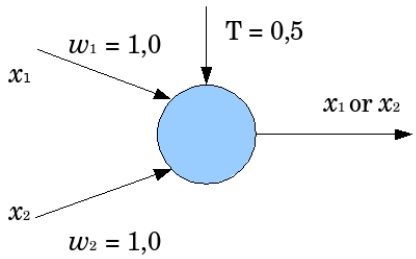



**Figure I.2 :** Représentation d'un neurone formel **[13].**

❖ **Modélisation d'un neurone formel**

Les réseaux de neurones formels sont à l'origine d'une tentative de modélisation mathématique du cerveau humain. Les premiers travaux datent de 1943 et sont l'œuvre deMM. Mac Culloch et Pitts. Ils présentent un modèle assez simple pour les neurones etexplorent les possibilités de ce modèle.

La modélisation consiste à mettre en œuvre un système de réseaux neuronaux 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.
On pourra résumer cette modélisation sur le tableau I.1, qui nous permettra de voir clairement la transition entre le neurone biologique et le neurone formel **[8].**

**Tableau I.1.** Analogie entre le neurone biologique et le neurone formel **[8].**

| **Neurone biologique** | **Neurone artificiel** |
|---|---|
| Synapses | Poids de connexions |
| Axones | Signal de sortie |
| Dendrite | Signal d'entrée |
| Somma | Fonction d'activation |

Nous avons vu, que les neurones sont des cellules organisées en « couche » : c'est à dire que lorsque un neurone reçoit un signal électrique par ses synapses, cela déclenche ou non

un autre signal sur la couche suivante, etc. Ce fonctionnement est reproduit dans les réseaux de neurones artificiels **[12].**

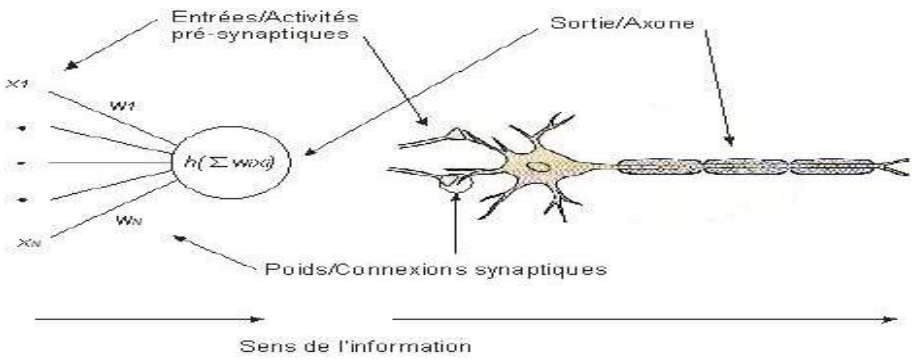



**Figure I.3**. Schéma de comparaison entre un neurone biologique et un neurone artificiel **[12].**

### I.3.6 Le modèle mathématique d'un neurone artificiel

Le modèle mathématique d'un neurone artificiel (ou "perceptron") est illustré à la figure ci-dessous. Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées (comme l'espérance statistique!). Le résultat $n$ de cette somme ensuite transformée par une fonction de transfert *f* qui produit la sortie *a* du neurone.

Les *R* entrées du neurone correspondent au vecteur noté traditionnellement en ligne (mais en fait on prend la transposée d'où le *T* en suffixe)

$$\vec{p} = \begin{pmatrix} p_1 \\ p_2 \\ \vdots \\ p_R \end{pmatrix}$$

Alors que :

$$\vec{w} = \begin{pmatrix} w_{1,1} \\ w_{1,2} \\ \vdots \\ w_{1,R} \end{pmatrix}$$

Représente le vecteur des poids du neurone (nous les distinguons pour préparer le terrain à des neurones un peu plus complexes).

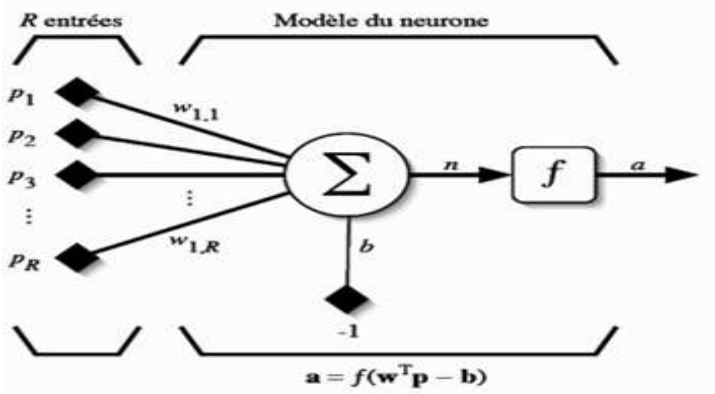



**Figure I.4**. Modèle mathématique du neurone artificiel **[14].**

La sortie *n* de l'intégrateur est définie par l'équation suivante :

$$n = \sum_{j=1}^{R} w_{1,j}\, p_j _ \text{b} = w_{1,1}p_1 + w_{1,2}p_2 + \ldots\ldots + w_{1,R}p_R _ \text{b} \qquad \text{(I.1)}$$

Que nous pouvons aussi écrire sous forme matricielle :

$$n = \overline{w^T}\,\bar{p} \text{ -b} \qquad \text{(I.2)}$$

Cette sortie correspond à une somme pondérée des poids et des entrées moins ce que nous nommons "le biais *b* du neurone" (facteur correctif décidé par tâtonnement). Le résultat *n* de la somme pondérée s'appelle le "niveau d'activation du neurone". Le biais *b* s'appelle aussi le "seuil d'activation du neurone". Lorsque le niveau d'activation atteint ou dépasse le seuil *b*, alors l'argument de *f* devient évidemment positif (ou nul). Sinon, il est négatif.

En ajoutant la fonction d'activation *f* pour obtenir la sortie du neurone :

$$a = f(n) = f(\overline{w^T}\,\bar{p} \text{ –b}) \qquad \text{(I.3)}$$

Il est temps maintenant de remplacer (pour alléger la notation) $\vec{w}^T$ par une matrice d'une seule ligne que nous noterons $W = \vec{w}^T$. Nous obtenons alors une forme générale que nous adopterons tout au long de notre étude :

$$a = f(n) = f(w\bar{p} \text{ –b}) \qquad \text{(I.4)}$$

Cette équation nous amène à introduire un nouveau schéma plus formel de notre perception des choses :

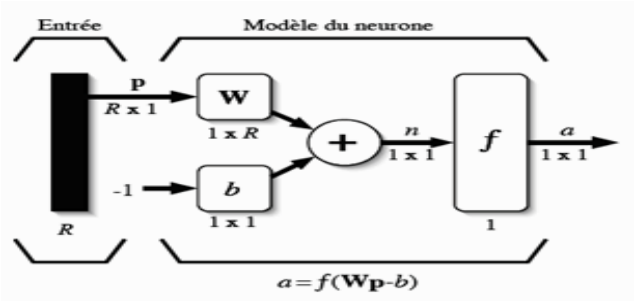



**Figure I.5.** Schéma plus formel d'un perceptron **[14].**

Nous y représentons les *R* entrées comme un rectangle noir (le nombre d'entrées est indiqué sous le rectangle). De ce rectangle sort le vecteur $\vec{p}$ dont la dimension matricielle est $R \times 1$. Ce vecteur est multiplié par une matrice *W* qui contient les poids (synaptiques) du neurone. Dans le cas d'un neurone simple, cette matrice possède la dimension $1 \times R$.

Le résultat de la multiplication correspond au niveau d'activation qui est ensuite comparé au seuil *b* (un scalaire) par soustraction. Finalement, la sortie du neurone est calculée par la fonction *f*. La sortie d'un neurone simple est alors toujours un scalaire **[14].**

### I.3.7 Fonction d'activation

La fonction d'activation, ou fonction de transfert, est une fonction qui doit renvoyer un réel proche de 1 quand les "bonnes" informations d'entrée sont données et un réel proche de 0 quand elles sont "mauvaises". On utilise généralement des fonctions à valeurs dans l'intervalle réel [0,1]. Quand le réel est proche de 1, on dit que l'unité (le neurone) est **active** alors que quand le réel est proche de 0, on dit que l'unité est **inactive.** Le réel en question est appelé la **sortie** du neurone et sera noté *a*. Si la fonction d'activation est linéaire, le réseau de neurones se réduirait à une simple fonction linéaire.

En effet, si les fonctions d'activations sont linéaires, alors le réseau est l'équivalent d'une régression multilinéaire (méthode utilisée en statistiques). L'utilisation du réseau de neurone est toutefois bien plus intéressante lorsque l'on utilise des fonctions d'activations non linéaires **[15].**

En notant *g* la fonction d'activation, on obtient donc la formule donnant la sortie d'un neurone:

$$a = g(in) = g(\sum_{i=0}^{k} w_i.x_i) \quad \text{(I.5)}$$

Remarquez que le coefficient de biais est inclus dans la somme, d'où la formule plus

explicite :

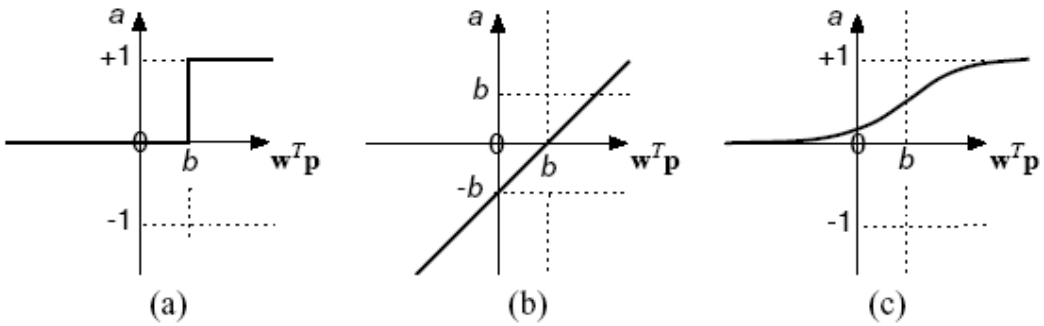
$$a = g(in) = g((\sum_{i=1}^{k} w_i.x_i) - w_0) \quad \text{(I.6)}$$

Jusqu'à présent, nous n'avons pas spécifié la nature de la fonction d'activation $a = f(n)$ de notre modèle. Il se trouve que plusieurs possibilités existent et celles-ci sont quasiment empiriques et à adapter en fonction des situations. Les plus courantes et les plus citées dans la littérature sont énumérées dans le tableau III.2 ci-dessous :

**Tableau. I.2.** Les fonctions de transfert les plus courantes **[14].**

| Nom de la fonction | Relation d'entrée/sortie | Icône |
|---|---|---|
| seuil | $a = 0$ si $n < 0$<br>$a = 1$ si $n \geq 0$ | |
| seuil symétrique | $a = -1$ si $n < 0$<br>$a = 1$ si $n \geq 0$ | |
| linéaire | $a = n$ | |
| linéaire saturée | $a = 0$ si $n < 0$<br>$a = n$ si $0 \leq n \leq 1$<br>$a = 1$ si $n > 1$ | |
| linéaire saturée symétrique | $a = -1$ si $n < -1$<br>$a = n$ si $-1 \leq n \leq 1$<br>$a = 1$ si $n > 1$ | |
| linéaire positive | $a = 0$ si $n < 0$<br>$a = n$ si $n \geq 0$ | |
| sigmoïde | $a = \frac{1}{1+\exp^{-n}}$ | |
| tangente hyperbolique | $a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$ | |
| compétitive | $a = 1$ si $n$ maximum<br>$a = 0$ autrement | C |

Les trois fonctions les plus utilisées dans le domaine de l'ingénierie sont les fonctions "seuil" (a) (en anglais "hard limite"), "linéaire" (b) et "sigmoïde" (c) comme représentées ci-dessous :




Comme son nom l'indique, la fonction seuil applique un seuil sur son entrée.

Plus précisément, une entrée négative ne passe pas le seuil, la fonction retourne la valeur 0 (faux), alors qu'une entrée positive ou nulle dépasse le seuil, et la fonction retourne 1 (vrai). Il est évident que ce genre de fonction permet de prendre des décisions binaires (cette fonction peut aussi être assimilée à la fonction de Heaviside).

La fonction linéaire est quant à elle très simple, elle affecte directement son entrée à sa sortie selon la relation $a = f(n) = n$. Il est évident que la sortie du neurone correspond alors à son niveau d'activation dont le passage à zéro (l'ordonnée à l'origine) se produit lorsque $W \cdot \vec{p} = b$.

La fonction de transfert sigmoïde est quant à elle définie par la relation mathématique :

$$a = \frac{1}{1 + e^{-n}} \tag{I.7}$$

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que nous sommesrespectivement loin ou près de *b*. La fonction seuil est très non linéaire car il y a une discontinuité lorsque $W \cdot \vec{p} = b$. De son côté, la fonction linéaire est tout à fait linéaire. Elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédentes. Notons finalement que la fonction tangente hyperbolique est une version symétrique de la sigmoïde **[14].**

### I.3.8 Architecture des réseaux

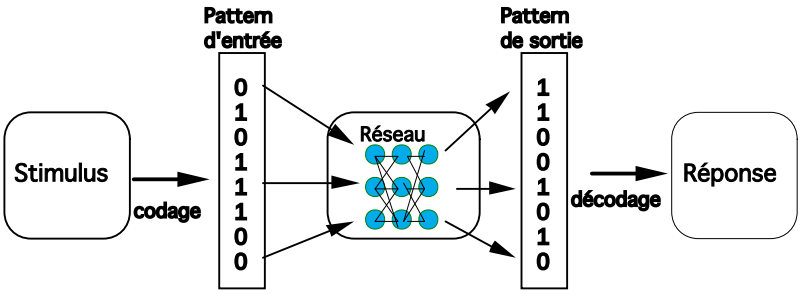



**Figure I.6.** Architecture générale d'un RNA **[16].**

Les connexions entre les neurones qui composent le réseau décrivent la topologie dumodèle. Elle peut être quelconque, mais le plus souvent il est possible de distinguer une certainerégularité (réseau à connexion complète) [ROS 97] **[8].**

- **Réseau monocouche**

La structure d'un réseau monocouche est telle que des neurones organisés en entrée soiententièrement connectés à d'autres neurones organisés en sortie par une couche modifiable de poids [YOU 99] (Figure I.7) **[8].**

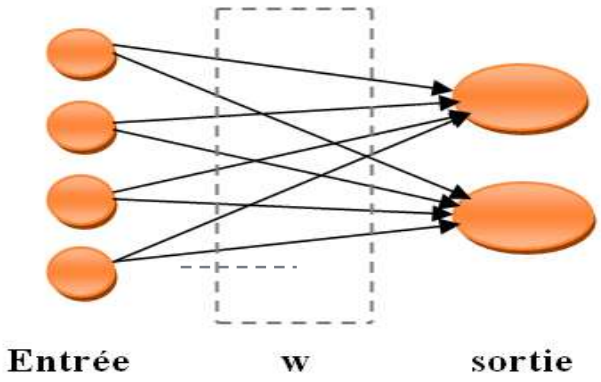



**Figure.7.** Réseau Monocouche **[17]**

- **Réseau multicouche [ROS 97]**

Les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche, et les connexions ne se font qu'avec les neurones de couches avales.

Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées (figure. I.8) **[8].**

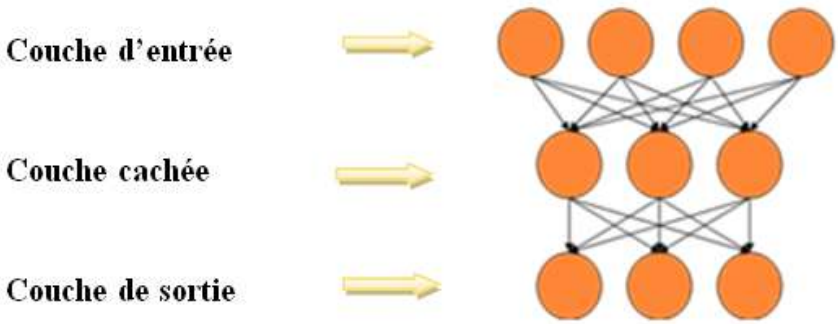



**Figure I.8.** Réseau Multicouche **[16].**

- **Réseau à connexion complète**

C'est la structure d'interconnexion la plus générale. Chaque neurone est connecté à tous lesneurones du réseau (et à lui-même) (Figure. I.9) **[8].**

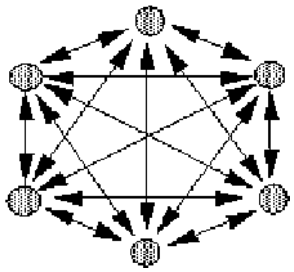


**Figure I.9. Réseau à connexions complètes [16].**

- **Réseau à connexions locales**

Il s'agit d'une structure multicouche, mais qui à l'image de la rétine conserve une certainetopologie. Chaque neurone entretient des relations avec un nombre réduit et

localisé deneurones de la couche avale. Les connexions sont donc moins nombreuses que dans le casd'un réseau multicouche classique (figure I.10) **[8].**

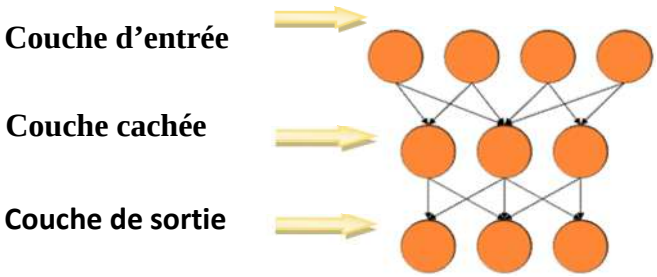



**Figure I.10.** Réseau à connexions locales **[16].**

### I.3.9 Apprentissage

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. On distingue deux grandes classes d'algorithmes d'apprentissage (figure I.11 et I.12) **[16].**

- L'apprentissage supervisé

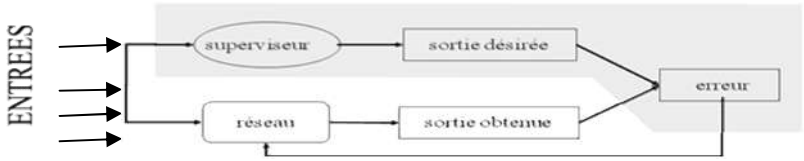



**Figure I.11 :** Schéma représentatif d'un apprentissage supervisé **[16].**

- L'apprentissage non supervisé

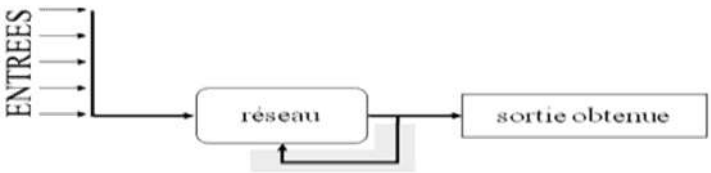



**Figure I.12.** Schéma représentatif d'un apprentissage non supervisé **[16].**

#### I.3.9.1 comment apprendre au réseau

Maintenant que l'on a créé un réseau, il faut lui faire apprendre quelque chose. Pour mieux comprendre cela, nous prendrons l'exemple de la reconnaissance de caractères : on présente des caractères au réseau et il a pour objectif de reconnaitre ce caractère. Par exemple, si on lui montre la lettre "a" dessinée, il doit nous répondre que cela est un "a".

Comment réaliser cela ? la méthode est en quelque sorte une imitation du cerveau :si la réponse est correcte,c'est bien, mais s'il y a une erreur, il faut modifier le réseau afin de ne pas réitérer l'erreur.

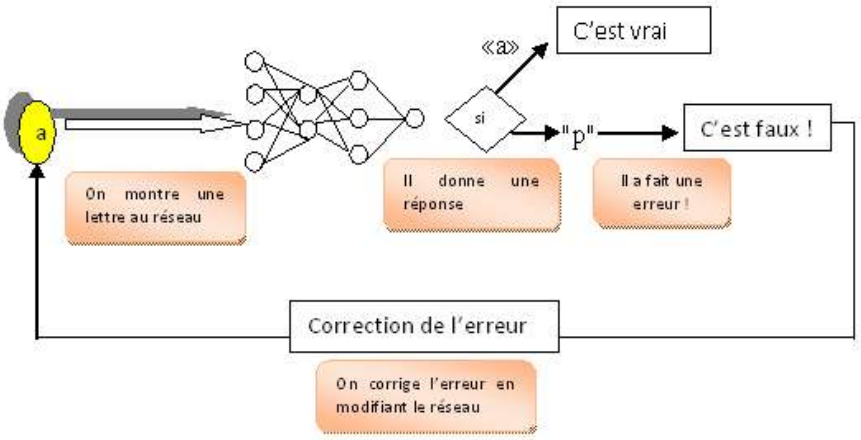



**Figure I.13** apprentissage du réseau

On recommence plusieurs centaines de fois l'opération, jusqu'à ce que le réseau ait bien appris sa leçon ! Le principe est donc relativement simple. On fait l'éduction du réseau comme on éduquerait un enfant : il faut lui répéter plusieurs fois qu'il a fait une erreur, et à la fin, il a appris **[7].**

### I.3.9.2 Surapprentissage

Il arrive souvent que les exemples de la base d'apprentissage comportent des valeurs approximatives ou bruitées. Si on oblige le réseau à répondre de façon quasi parfaite relativement à ces exemples, on peut obtenir un réseau qui est biaisé par des valeurs erronées. Par exemple, imaginons qu'on présente au réseau des couples (xi, f (xi)) situés sur une droite d'équation y=ax+b, mais bruités de sorte que les points ne soient pas exactement sur la droite. S'il y a un bon apprentissage, le réseau répond ax+b pour toute valeur de x présentée. S'il y a surapprentissage, le réseau répond un peu plus que ax+b ou un peu moins, car chaque couple (xi, f (xi) positionné en dehors de la droite va influencer la décision. Pour éviter le surapprentissage, il existe une méthode simple : il suffit de partager la base d'exemples en 2 sous-ensembles. Le premier sert à l'apprentissage et le $2^{ème}$sert à l'évaluation de l'apprentissage. Tant que l'erreur obtenue sur le $2^{ème}$ ensemble diminue, on peut continuer l'apprentissage, sinon on arrête **[7].**

### I.3.9.3 Rétropropagation

La rétropropagation consiste à rétropropager l'erreur commise par un neurone à ses synapses et aux neurones qui y sont reliés. Pour les réseaux de neurones, on utilise habituellement la rétro propagation du gradient de l'erreur, qui consiste à corriger les erreurs selon l'importance des éléments qui ont justement participé à la réalisation de ces erreurs : les poids synaptiques qui contribuent à engendrer une erreur importante se verront modifiés de manière plus significative que les poids qui ont engendré une erreur marginale **[7].**

### I.3.9.4 Élagage

L'élagage ("pruning", en anglais) est une méthode qui permet d'éviter le surapprentissage tout en limitant la complexité du modèle. Elle consiste à supprimer des connexions (ou synapses), des entrées ou des neurones du réseau une fois l'apprentissage terminé.

### I.3.9.5 Précision

En pratique, les éléments qui ont la plus petite influence sur l'erreur de sortie du réseau sont supprimés. Les deux algorithmes d'élagage les plus utilisés sont :

- Optimal Brain Damage (OBD) d'Y. LeCun et al.
- Optimal Brain Surgeon (OBS) de B. Hassibi et D.G. Stor **[18].**

## I.4 Conclusion

Un réseau de neurones est un outil d'analyse statistique permettant de construire un modèle de comportement a partir de données qui sont des exemples de ce comportement. Essentiellement utilisés pour faire de la classification.

Grace à leur grande capacité d'apprentissage automatique à partir de données modélisant le problème à résoudre, les réseaux de neurones permettent de remplacer efficacement des modèles mathématiques pouvant être extrêmement complexes. Dans ce chapitre nous avons donné un rappel sur les réseaux de neurones (les grands types, leurs applications…etc.) de façon générale.

# Chapitre II  Maintenances des machines tournantes par analyse des vibrations

# Chapitre 2: Maintenances des machines tournantes

## II.1.Introduction

Les machines tournantes peuvent avoir plusieurs sortes de conséquences défavorables sur la sûreté de fonctionnement (fiabilité, disponibilité, sécurité, maintenance), sur la sécurité des personnes, sur l'environnement ainsi que sur l'économie et la politique. Toutes ces conséquences poussent à augmenter le niveau de leurs performances (productivité, qualité) et à diminuer leur coût global mesuré tout au long de leur cycle de vie.

Les machines tournantes en fonctionnement produisent des vibrations et leur dysfonctionnement se traduit souvent par une modification de répartition de l'énergie vibratoire. En observant l'évolution du niveau de vibrations, il est possible d'obtenir des informations très utiles sur l'état de la machine.

## II.2.Machines tournantes

Les machines tournantes sont des systèmes comporte au moins:

- Un rotor
- Une structure
- Des liaisons

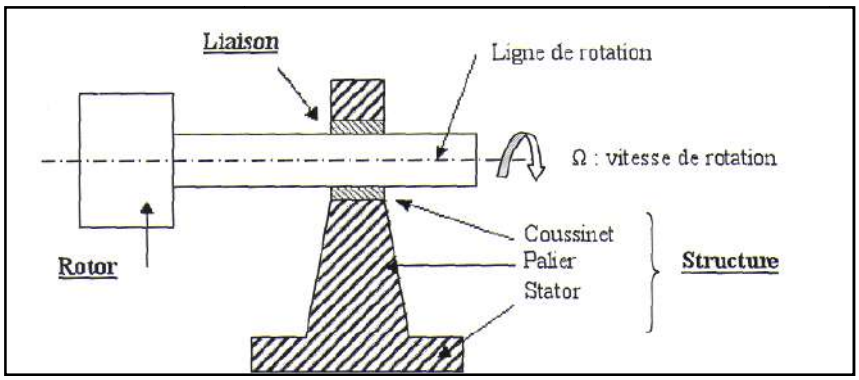



**Figure II.1 :** machine tournante

Le rotor tourne autour d'une ligne de rotation par l'intermédiaire de liaisons ayant pour support la structure de la machine. La rotation du rotor engendre des forces qui dépendent de l'état des machines. Ces efforts vont se répercuter sur tous les éléments de la machine.

## II.3.Maintenance des machines tournantes

Existe trois grands types de maintenance : la maintenance corrective, la maintenance préventive systématique et la maintenance préventive conditionnelle suivi éventuellement de la maintenance prévisionnelle appelée souvent aussi maintenance prédictive. Ces trois types de maintenance sont schématisés par la figure (II.2).

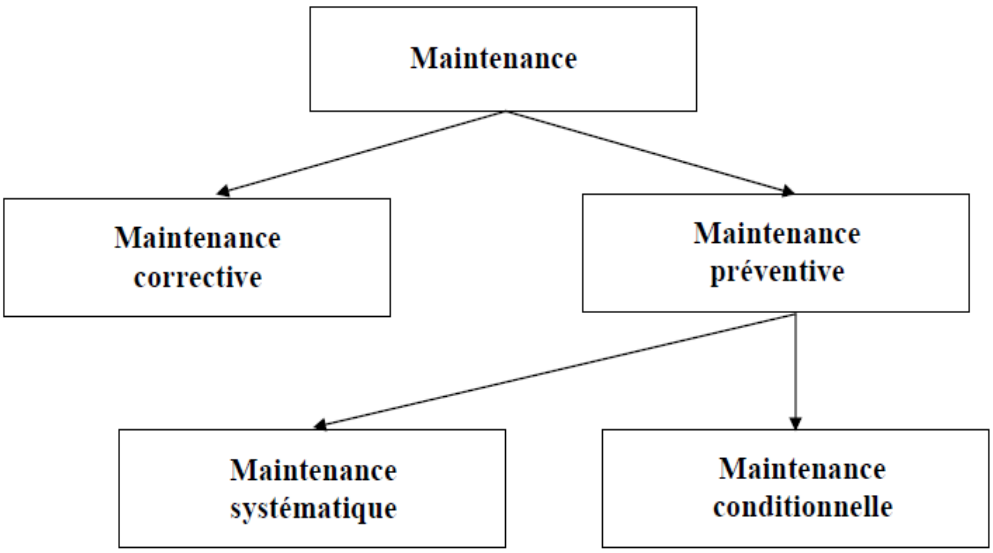



**Figure II.2** : Différents types de maintenance

La maintenance corrective (figure II.2) est appliquée après la panne, comme par exemple la rupture d'une pièce mécanique. Ce type de maintenance est réservé au matériel peu coûteux, dont la panne aurait peu d'influence sur la production, la qualité du produit fini ou la sécurité.

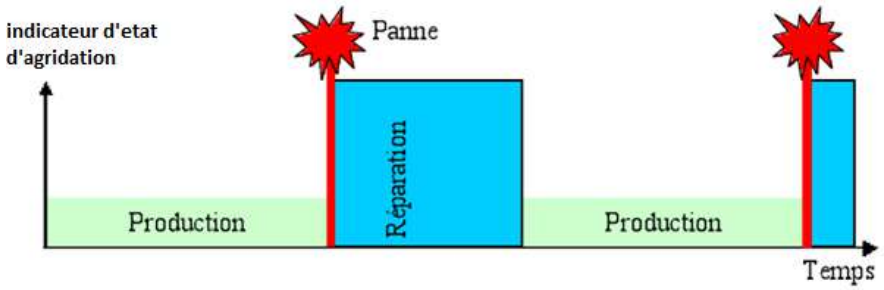



**Figure II.3** Maintenance corrective

La maintenance systématique (figure II.3) est une maintenance préventive effectuée avant la panne par des interventions régulières, selon un calendrier préétablit en fonction de la nature du matériel et des impératifs de production. L'entretien intervient à intervalles réguliers, fixé sur la base du minimum de vie des composants données par l'expérience ou préconisés par les constructeurs.

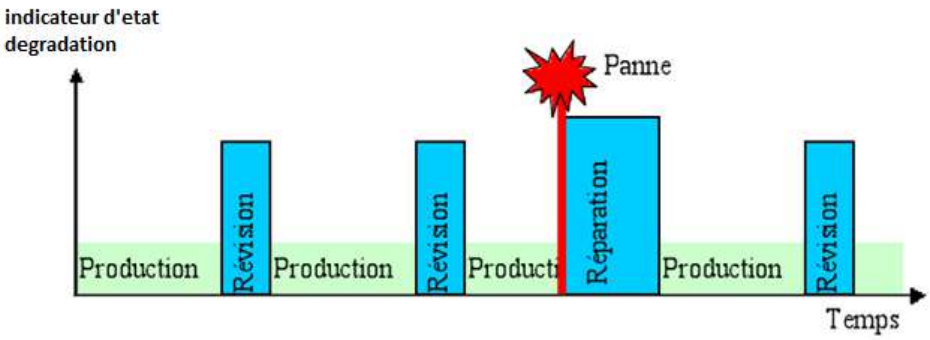



**Figure II.4** : Maintenance systématique

La maintenance conditionnelle (figure II.4) est une maintenance préventive effectuée avant la panne par des interventions de façon conditionnelle, c'est-à-dire uniquement si certains paramètres (vibration, bruit, température.) évoluent de façon significative.

La maintenance prévisionnelle (ou prédictive) définit un prolongement de la maintenance conditionnelle destiné à repousser au maximum les opérations de maintenance à effectuer. Elle a pour rôle d'analyser la tendance évolutive du dysfonctionnement après que celui-ci est détecté sur un appareil de mesure et d'estimer le temps pendant lequel il est possible de continuer à l'utiliser avant la panne.

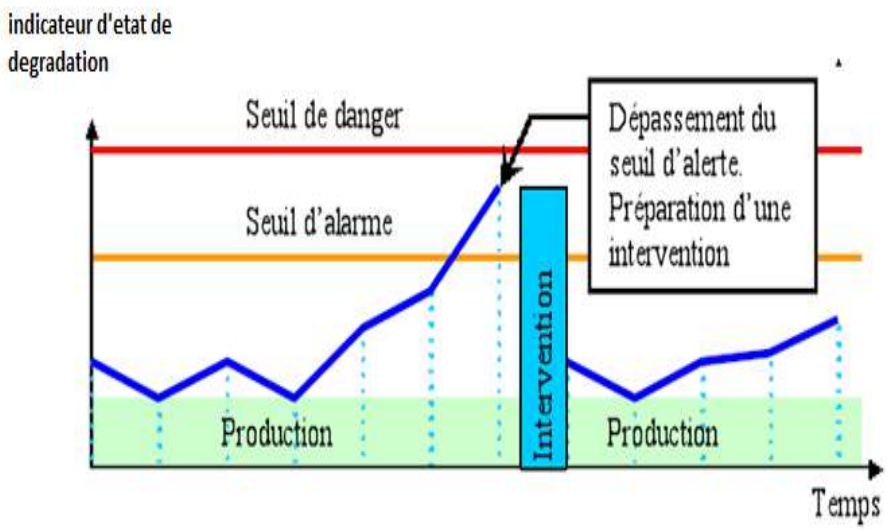



**Figure II.5**: Maintenance préventive conditionnelle

## II.4. Méthode de surveillance des machines

Le terme de surveillance de l'état d'une machine regroupe l'ensemble des opérations qui permettent de quantifier la capacité d'un matériel à remplir sa fonction par rapport à des caractéristiques et consignes définies soit au départ soit au cours du fonctionnement. Le principe consiste à établir un diagnostic en choisissant un ou plusieurs paramètres de fonctionnement à des données standards (ou d'expertise) caractérisant la présence d'anomalies de fonctionnement. Ce diagnostic présente donc l'intérêt de permettre la détermination de l'instant où commence une dégradation, et de décider ainsi de l'intervention moment optimal. La figure II.6 regroupe les méthodes utilisées dans l'industrie pour effectuer des opérations surveillance [21] et [22].

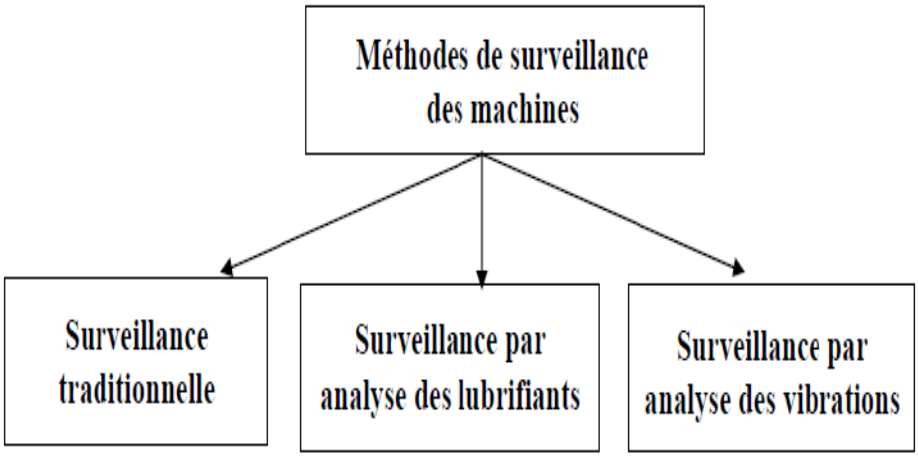



**Figure II.6.**Méthodes de surveillance des machines

### II.4.1. Surveillance traditionnelle

Ces méthodes contiennent celles qui sont utilisées depuis longtemps par le service de maintenance. Parmi celles-ci, on trouve les mesures : de température, de pression, etc. La température est un paramètre très important qui peut indiquer le bon fonctionnement moyen d'une machine. Schématiquement, il existe deux types de mesure de température, soit celle :

- située dans la zone où apparaît le défaut produit par un frottement entre deux pièces,
- différée lorsque la chaleur est transmise par l'intermédiaire d'un fluide. Par exemple, pour les réducteurs à engrenage, on mesure la température d'huile près de la surface des dents où se produit le contact. Cependant, il n'est pas toujours facile de mesurer cette température avec précision. De même, cette méthode ne permet pas de faire un diagnostic précis et exige une surveillance continue, d'où la limitation de cette technique.

La mesure de la pression peut être considérée comme une méthode complémentaire de la méthode précédente. La pression ou la dépression en un point d'une machine est un paramètre pouvant renseigner sur son état. Cette surveillance peut être faite de façon continue ou programmée. Toute anomalie constatée entraînera l'arrêt de la machine ; on devra par la suite chercher le défaut puisque généralement cette méthode ne permet aucun diagnostic.

### II.4.2.Surveillance par analyse de lubrifiant

Cette méthode est appliquée en temps différé, elle impose généralement un état particulier avec un arrêt de la machine. Cette méthode est basée sur l'analyse de la dégradation et de la contamination des huiles :

- la dégradation d'un lubrifiant se produit par oxydation ou l'action de la température et de l'oxygène de l'air. Cette dégradation entraîne une altération des caractéristiques des lubrifiants ainsi que la formation de dépôts susceptibles d'obstruer les canalisations d'huile. Ce paramètre fournira donc un certain nombre de renseignements sur le fonctionnement de la machine : refroidissement incorrect, etc.
- la contamination des lubrifiants est provoquée par des débris d'usure, des particule ssolides, et de l'eau en provenance de l'extérieur du système lubrifié. Le taux de contamination et la nature de cette contamination seront donc des éléments riches en informations sur l'état mécanique de la machine.

Il existe deux types d'examen des huiles, qui sont :

a) les examens physico-chimiques qui, dans le cas des moteurs à combustion interne, donneront les informations concernant la combustion,

b) les examens spectrométriques qui donnent les informations sur l'usure. Ainsi, on peut établir la teneur en métaux de l'huile.

Cette méthode présente même certains avantages sur l'analyse des vibrations telles que la détection de micropitting. Mais, elle présente aussi des inconvénients qui sont :

- difficulté d'établir un catalogue complet regroupant toutes les pièces susceptibles des user. Pour une machine donnée, de même plusieurs pièces peuvent avoir la même composition. Le diagnostic portera rarement sur l'élément mais soumettra des hypothèses sur un ensemble,
- impossibilité de prévoir les avaries à évolution rapide vu que les analyses se font à intervalles réguliers,
- les ajustements des machines modernes sont de plus en plus précis dans le souci de diminuer les usures. De ce fait, les indications contenues dans l'huile sont de plus en plus ténues. La

finesse de l'analyse doit donc être de plus en plus grande et c'est elle qui fixe « résolution » de la surveillance des machines par l'analyse d'huile.

## II.5.Analyse des vibrations

Les machines tournantes en fonctionnement produisent des vibrations et leur dysfonctionnement se traduit souvent par une modification de répartition de l'énergie vibratoire. En observant l'évolution du niveau de vibrations, il est possible d'obtenir des informations très utiles sur l'état de la machine.

La surveillance de l'état d'une machine tournante se fait par l'analyse des vibrations. Cette analyse est l'outil le plus utilisé à causes de la capacité des données vibratoires à donner la mesure la plus pertinente de l'état d'une machine en fonctionnement et à prédire de façon précoce le développement des défauts.

En pratique, l'analyse des vibrations se décompose en quatre phases distinctes:

- La détection du défaut qui se développe,
- Le diagnostic dès qu'une anomalie est détectée,
- Le pronostic qui vise à suivre l'état d'endommagement de chacun des éléments défectueux et prédire sa durée de vie résiduelle,
- L'expertise des pièces mécaniques après démontage.

D'autre part, l'analyse vibratoire, fait ressortir trois étapes principales:

- Acquisition des données,
- Traitement des données,
- Prise de décision de maintenance

### II.5.1.Amplitude d'un signal vibratoire

Une vibration se caractérise principalement par sa fréquence, son amplitude et sa phase. On appelle amplitude d'une onde vibratoire la valeur de ses écarts par rapport au point d'équilibre. On peut définir :

- **L'amplitude maximale par rapport au point d'équilibre** appelée également amplitude crête (Ac).
- **L'amplitude double,** aussi appelée amplitude crête à crête (Acc)
- **L'amplitude efficace** ($A_{eff}$), aussi appelée RMS (root mean square en anglais).

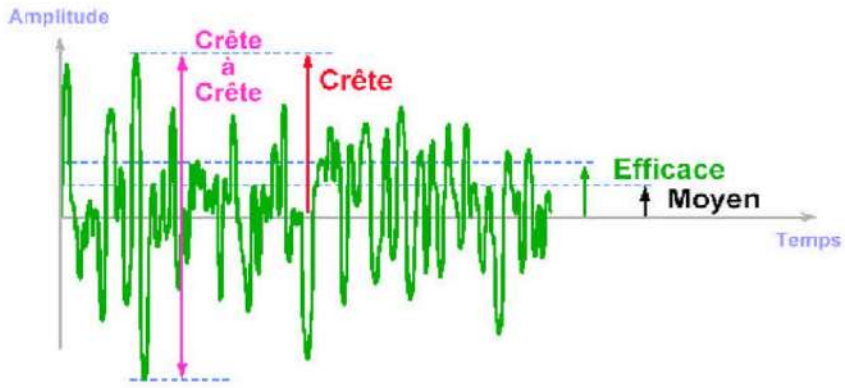



**Figure II.7** Amplitude de signale vibratoire

Divers indicateurs sont utilisés dans le suivi vibratoire des roulements, on peut citer à cet effet, la valeur de l'accélération efficace (ou RMS), le Kurtosis, la valeur crête (VC) et le Facteur de crête (FC).

L'accélération efficace $Acc_{eff}$, (ou *RMS*) est définie par l'expression suivante:

$$Acc_{eff} = \sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2} \qquad \text{(II.1)}$$

$x_i$ L'amplitude du signal pour l'échantillon i, [m/s$^2$]

N le nombre d'échantillons prélevés dans le signal.

Le Kurtosis est un paramètre statistique permettant d'analyser la répartition des amplitudes vibratoires continues dans un signal temporel. Défini comme suit :

$$Kurtosis = \frac{\frac{1}{N}\sum_{i=1}^{N}\left(x_i - \bar{x}\right)^4}{\left[\frac{1}{N}\sum_{i=1}^{N}\left(x_i - \bar{x}\right)^2\right]^2} \qquad \text{(II.2)}$$

Avec $\bar{x} = \frac{1}{N}\sum_{i=1}^{N} x_i$

$\bar{x}$ La valeur moyenne des amplitudes, tel que :

Le facteur de crête *FC* correspond au rapport entre la valeur crête d'un signal (en valeur absolue) et sa valeur efficace. Défini comme suit:

$$FC = \frac{Acc_{crête}}{Acc_{eff}} = \frac{sup\ |x_i|}{\sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2}} \qquad (II.3)$$

La présence d'une anomalie peut être détectée si un indicateur dépasse un seuil prédéterminé. Les seuils, sont définis, soit par la norme (par exemple : ISO10816), soit par expérience. En pratique, le Kurtosis d'un signal sans défaut est égale à trois et que le facteur de crête du même signal peut varier de 3 à 6. De ce fait, ils sont indicateurs de la présence d'un choc si leurs valeurs dépassent ces seuils.

## II.6.Les différents défauts des machines tournantes

Le déséquilibre massique du rotor ;

• dégradation de roulement ;
• désalignement des axes (des accouplements, arbre palier, ....etc.) ;
• détérioration des dents d'engrenage ;
• défauts transmis par courroie ;
•défaut de frottement ;
• défaut par desserrage ;
• défaut induit par l'électromagnétisme. Les méthodes et techniques mises en jeu pour l'identification et la détection de ces défauts sont :

- ❖ analyse vibratoire ;
- ❖ démodulation en fréquence / en phase ;
- ❖ analyse de Fourier ;
- ❖ analyse d'enveloppe ;
- ❖ analyse temps fréquence ;
- ❖ analyse spectrale ;
- ❖ analyse cepstrale ;
- ❖ analyse cyclostationnaire ;
- ❖ analyse statistique ;
- ❖ méthode de reconnaissance de forme.

Il existe d'autres méthodes récentes et complexes telles que : les réseaux de neurones, la logique floue, les méthodes de détection par l'émission acoustique et les méthodes d'intelligence artificielle etc.

### II.7. Les roulements

Toute machine tournante comporte un ou plusieurs paliers constituant l'interface entre la partie tournante et la partie fixe. Comme les autres composantes, ces éléments ne sont ni parfaits, ni inusables. Leur fonctionnement provoque également des vibrations. Parmi tous les organes constitutifs des machines, les roulements ont fait l'objet d'études particulières et contradictoires de la part des responsables de la surveillance. D'autre part, on leur porte beaucoup d'attention parce qu'ils constituent les éléments les plus communs et les plus nombreux dans les machines, et parce que le séparation qu'ils opèrent entre ce qui tourne et ce qui est fixe leur confère un rôle privilégié. De plus, la plupart des mauvais fonctionnements (balourds, désalignement,…) se répercutent directement sur leur état.

Dans le cas de vibrations provoquées par les roulements, les défauts sont très localisés sur les éléments (écaillage, rayures…) (Figure II.8.B) ou, au contraire, très étendus (défaut de forme, corrosion, usure de piste) (Figure II.8.A). Dans le premier cas, les fréquences des vibrations qui apparaissent peuvent aisément se calculer, puisqu'elles correspondent à des impacts chaque fois que les défauts isolés passent dans les surfaces de contact des éléments. Dans les seconds cas, si les défauts sont uniformément répartis sur toutes les parties actives du roulement, les vibrations ne se trouvent plus à ces fréquences calculables, mais se répartissent dans une large moyenne spectrale.

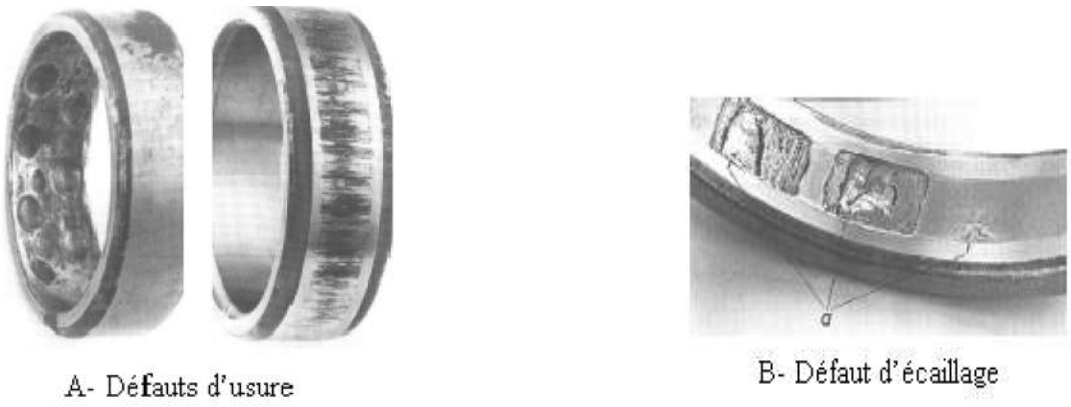



**Figure II.8** Défauts réels de roulements réparti et localisé [23]

La fréquence d'apparition d'un défaut de roulement peut être connue à partir de la géométrie et de la cinématique du système. Un calcul cinématique permet de déterminer les fréquences d'apparition des défauts locaux pouvant survenir sur un roulement. Ces fréquences sont données en fonction de cotes de fabrication de roulement et de la vitesse de rotation. On peut considérer quatre fréquences caractéristiques :

BPFO : Défaut de bague extérieure.

BPFI **:** Défaut de bague intérieure.

$f_e$: Défaut d'élément roulant.

$f_c$: Défaut de cage.

Les formules ci-dessous donnent les expressions des fréquences caractéristiques des défauts des roulements, Avec :

$N_b$: Le nombre d'éléments roulants (billes, rouleaux ou aiguilles)

*D* : Le diamètre primitif

*d*: Le diamètre des éléments roulants

$\alpha$: L'angle de contact.

$f_{rot}$: La fréquence de rotation de la bague interne (la bague externe étant supposé fixe)

Ainsi, nous avons:

La fréquence de passage d'une bille (ou d'un rouleau) sur un défaut de bague externe (la bague externe étant supposée fixe) :

$$BPFO = \frac{f_{rot-N_b}}{2}\left(1-\frac{d}{D}\cos\alpha\right) \quad \text{(II.4)}$$

La fréquence de passage d'une bille (ou d'un rouleau) sur un défaut de bague interne (la bague interne étant supposé montée sur l'arbre tournant) :

$$BPFI = \frac{f_{rot-N_b}}{2}\left(1+\frac{d}{D}\cos\alpha\right) \quad \text{(II.5)}$$

La fréquence de passage d'un défaut de cage, $f_c$ est donnée par l'équation suivante:

$$f_c = \frac{f_{rot}}{2}\left(1-\frac{d}{D}\cos\alpha\right) \quad \text{(II.6)}$$

La fréquence de passage d'un défaut de bille (ou de rouleau) sur la bague externe ou sur labague interne, $f_e$est donnée par l'équation suivant :

$$f_e=\frac{f_{rot}}{2}.\frac{D}{d}(1-(\frac{d}{D}cos\alpha)^2) \quad \text{(II.7)}$$

Mais comme le choc dû au défaut se produit à chaque tour de bille (ou de rouleau), à la fois sur la bague interne et sur la bague externe, on donne généralement :

$$2.f_e=f_{rot}.\frac{D}{d}(1-(\frac{d}{D}cos\alpha)^2) \quad \text{(II.8)}$$

Les fréquences de passage des défauts sont des fréquences théoriques sensiblement respectées tant qu'il y a roulement sans glissement des billes. Dès qu'il y a amorce de grippage, le frottement a tendance à ralentir la partie dégradée. Le défaut se manifeste donc à une fréquence inférieure à la fréquence calculée.

Cette différence, bien que, difficile à appréhender, est un élément décisif pour établir l'urgence de l'intervention, le grippage étant le stade ultime d'un défaut sur roulement et pouvant amener par blocage la dégradation brutale du rotor

## II.8.Modes de défauts de roulement

La durée de vie normale d'un roulement sous une charge est déterminée par l'usage et la fatigue des surfaces des éléments du roulement. Des échecs prématurés de roulement peuvent être provoqués par un grand nombre de facteurs. Les plus communs sont la fatigue, la détérioration, la corrosion, et une faible lubrification. Les sections suivantes décrivent les modes communs de défaut de roulement.

### II.8.1.La fatigue

Un roulement est mis sous une charge normale alternée a pu perdre en raison de la fatigue du métaux après un certain temps d'opération. Les défauts dûs à la fatigue commencent par une formation des petites fissures au-dessous de la surface d'appui. Pendant que le chargement continue, les fissures progressent sur les surfaces dans les sections de contact. L'origine réelle peut se manifester comme piqûre de corrosion. Si le roulement est maintenu en service, les endommagements s'étendront à proximité du défaut dû à la concentration d'effort. Les défauts extérieurs troublent sévèrement le mouvement nominal du roulement et de ses éléments en présentant des chocs répétés à temps courts et aux fréquences caractéristiques de défauts des éléments constituant le roulement. Si le roulement devait

continuer en service, les défauts peuvent atteindre d'autres éléments et par la suite mener à l'augmentation du frottement et de la température **[24]**.

### II.8.2.L'usure (The wear)

La détérioration est une autre cause commune de défaut de roulement. Elle est provoquée principalement par la saleté (l'obscénité) et les particules étrangères pénétrant le roulement par le cachetage insatisfaisant ou en raison du lubrifiant souillé. Les particules étrangères abrasives rendent les surfaces de contact rudes (résistant) donnant un aspect mat. La détérioration grave change le profil de la course, change le profil et le diamètre d'élément roulant, et augmente le dégagement ou l'enlèvement du roulement. Le résultat final dans ce cas est une panne complète. La détérioration croissante présente graduellement des erreurs géométriques dans le roulement. Les diamètres non -uniformes des éléments usés de roulement sont la cause des vibrations et des harmoniques de fréquence de cage. Les erreurs géométriques des courses peuvent produire en conséquence des harmoniques multiples à la vitesse de rotation de l'axe **[24]**.

### II.8.3.La corrosion

Le défaut de corrosion se produit quand l'eau, les acides ou d'autres contaminants se mélangent avec le lubrifiant (huile). Ceci peut être provoqué par les joints endommagés. Les lubrifiants acides ou la condensation qui se produit quand les roulements sont soudainement refroidis à une température de fonctionnement plus élevée que celle ce l'air très humide provoquent la rouille sur les couches superficielles du roulement qui produit des opérations inégales et bruyantes pendant que les particules de rouille interfèrent la lubrification. Les particules de rouille ont également un effet abrasif ce qui produit la détérioration de roulement. Les puits de rouille forment également l'initiation de l'écaillement et la délitescence **[25]**.

### II.8.4.Le faux brinellage

Le faux brinellage peut affecter le roulement au repos et les roulements dont les bagues tournent à la même vitesse. C'est une usure par petits débattements qui cassent et conduisent à un contact métal-métal.

Des microsoudures et des microarrachements en résultent ; les particules s'oxydent et contribuent à une destruction qui peut être rapide.
Des empreintes brillantes, ou ternes, s'installent aux endroits des éléments roulants **[25]**.

### II.8.5.L'absence de lubrification

La lubrification insatisfaisante, en termes de quantité ou de qualité, est l'une des causes communes de l'échec prématuré des roulements.

A la région de contact Hertzien soumise à une forte contrainte, quand il y a insuffisance de lubrifiant, les surfaces en contact se soudent ensemble. Les trois points critiques de lubrification de roulement se produisent à l'interface de la cage-rouleau, à l'interface de la course-rouleau (ou bille) et à l'interface de la course-cage. L'absence du lubrifiant ou le choix inexact du lubrifiant peut avoir des conséquences graves pendant que les températures élevées peuvent recuire les éléments de roulement et réduire la dureté et la vie en fatigue. Par la suite, l'utilisation successive d'un roulement détérioré peut provoquer des catastrophes graves **[24]**.

### Et d'autres défauts

− Un défaut de type écaillage affectant la bague externe d'un roulement a pour image vibratoire un peigne de raies. A chaque composant de ce peigne, est associée une paire de bande latérale espacée de la fréquence de rotation, en cas de charge dynamique importante **[26]**.

− Un défaut de type écaillage affectant la bague interne d'un roulement a pour image vibratoire un peigne de raies. Sont associées plusieurs paires de bandes latérales espacées de la fréquence de rotation.



**a)** Défaut sur la bille "détérioration de la bille" **[27]**



**b)** Défaut de piste interne. **[28]**

**Figure II.9.(a ,b).** Défaut de bille et un écaillage de la bague interne



**Figure II.10.** Mode de détection de défaut de roulement **[29]**

Un défaut de type écaillage sur un élément roulant, a pour image vibratoire un peigne de raies, ils sont associés plusieurs paires de bandes latérales espacées de la fréquence de rotation pour chaque composante de ce peigne.

Le défaut de type déversement de bague externe a pour image vibratoire une raie importante à la fréquence de cette bague, qui est généralement prépondérante par rapport à ses premiers harmoniques. Le déversement de la bague interne a pour image vibratoire une raie importante à la fréquence de défaut de cette bague, qui est généralement modulée par la fréquence de rotation. Le déversement simultané des deux bagues a évidemment une image vibratoire conjuguant les images des deux types de défauts.

Les images vibratoires des différents défauts de roulement sont présentées sur les figures ci-dessous :

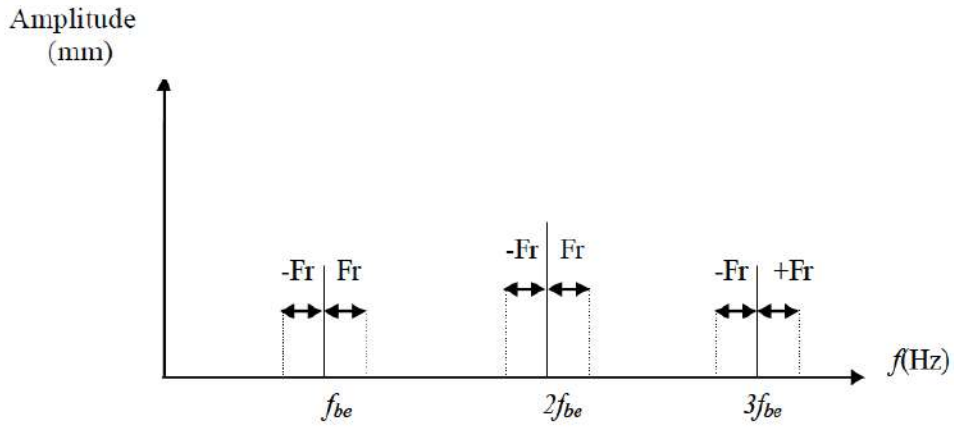



**Figure II.11.**Image vibratoire d'un défaut de la bague externe

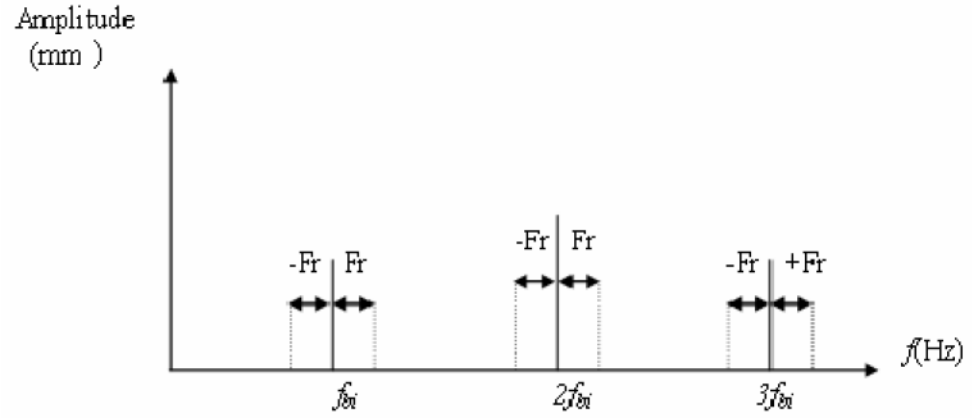



**Figure II.12.** Image vibratoire d'un défaut de la bague interne

## II.9.Processus de dégradation d'un roulement

Lorsqu'un roulement tourne, les contacts métalliques entre Les éléments roulants et les cages émettent des bruits de fond aléatoires.

Ce bruit de fond créé un spectre plat La plupart des usures de roulements débute par une fêlure qui se transforme en craquelure. La craquelure va produire des impacts énergétiques en haute fréquence.

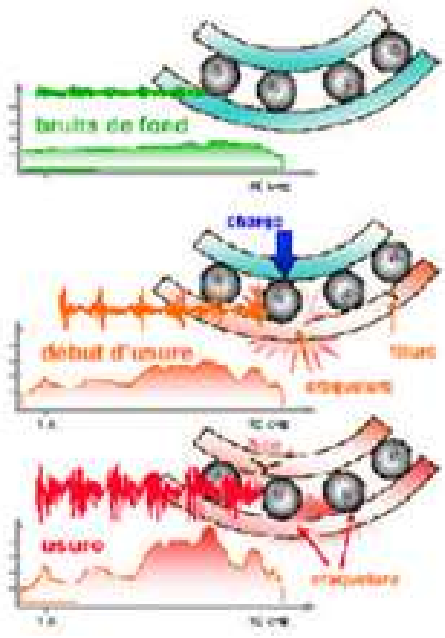



**Figure II.13.**Dégradation d'un roulement

Au fur et à mesure que l'usure progresse:

- Les défauts tendent à se lisser
- Il y a moins d'impacts;
- Le bruit de fond de la bonne piste devient modulé;
- Dès que le défaut est significatif, les billes vont eroder la cage interne en sautant.

## II.10.Analyse vibratoire des défauts de roulements

Différentes méthodes d'analyse vibratoire, basées sur le comportement du roulement, permettent de détecter, de diagnostiquer et de pronostiquer les défauts de roulements. Ces méthodes ont fait l'objet de nombreuses publications synthétisées dans les références [30.31.32]. On peut classer ces méthodes en trois grandes familles: les méthodes temporelles basées sur l'analyse statistique du signal, les méthodes fréquentielles basées sur la transformée de Fourier et les méthodes basées sur l'analyse des deux domaines temps et fréquence en même temps. Les méthodes temporelles s'appliquent à des machines simples et consistent à effectuer des mesures de vitesse dans des gammes de fréquences faibles (de 10Hz à 1000 Hz) et des mesures d'accélérations dans des gammes de fréquences élevées (de 1000 Hz à 10000 Hz) dans le but de minimiser l'influence des vibrations induites par la rotation des arbres. Les méthodes fréquentielles permettent une localisation des défauts issus des roulements, à partir de la connaissance des fréquences caractéristiques, elles sont très bien adaptées aux systèmes complexes

## II.11.Détection des défauts

Le processus de détection des défauts de roulement s'appuie sur l'analyse statistique du signal temporel. Dans cette analyse, on calcule les indicateurs globaux comme la valeur efficace de l'accélération, la valeur crête de l'accélération, le facteur de crête, le facteur k, le kurtosis. Ces indicateurs évaluent l'état de fonctionnement global des équipements mais ne permettent pas de localiser et identifier le défaut **[33].**

### II.11.1.La valeur efficace du signal *(ou RMS Root Mean Square)*

C'est un indicateur qui mesure le contenu énergétique dans un signal temporel. Sa valeur correspond à la racine carrée de la moyenne du carrée du signal *x(t)* calculée sur une période T.

$$\text{RMS}= \sqrt{\frac{1}{T}}.\int_i^{i+T} x^2(t).dt \qquad \text{(II.9)}$$

Et pour une variable discrète $\{xxii\}$

$$RMS= \sqrt{\frac{1}{n}}\sum_{i=1}^{n} x_i^2 \qquad \text{(II.10)}$$

Où *n* et $x_i$sont le nombre d'échantillons prélevés dans le signal et l'amplitude du niveau vibratoire mesuré filtré ou non, respectivement. La mesure de la valeur RMS est une technique approximative d'analyse du signal qui fait abstraction du paramètre fréquentiel pour ne mesurer que l'amplitude. Les valeurs données ne sont représentatives que du phénomène prépondérant en amplitude dans la plage de fréquences mesurées, phénomène qui, bien qu'ayant la plus grande amplitude n'est pas forcément le plus inquiétant et qui a tendance à masquer la valeur des autres phénomènes. C'est ce que l'on appelle l'effet de masque. C'est à cause de cet effet de masque, qu'il faut effectuer un tri entre les phénomènes basses fréquences (balourd, désalignement), moyennes fréquences (défauts d'engrenages ou de passage des pales) et hautes fréquences (défauts de roulements). Cette méthode est appelée mesures par bandes de fréquences dont le nombre, établi en fonction de la complexité cinématique de la machine, qualifie la fiabilité de la surveillance. On prend bien soin de donner à chaque plage de fréquences un seuil d'alerte approprié.

Le calcul de la valeur efficace des vibrations de roulements requiert d'effectuer des mesures de niveau vibratoire en mode accélération, dans une large bande de fréquences, généralement comprise entre 1 KHz et 20 KHz. Les avantages de cette méthode résident dans sa simplicité et sa rapidité de mise en œuvre, et demande un investissement en matériel faible. Cependant, la valeur efficace ne détecte pas tous les défauts et donne une alarme tardive, ce qui représente

un inconvénient majeur dans le cadre de la maintenance conditionnelle. La présence d'une anomalie peut être détectée si un indicateur dépasse un seuil prédéterminé. Les seuils sont définis généralement d'une façon expérimentale. Il est possible de fixer, au départ, un seuil d'alerte et un seuil de danger comme suit : si une mesure dépasse le niveau d'alerte, cela signifie que l'accélération relevée est deux fois plus importante que celle qui fait référence. Et si une mesure dépasse le niveau de danger, cela signifie que l'accélération relevée est dix fois plus importante que celle qui fait référence.

### II.11.2.Les indicateurs crêtes

Les indicateurs crêtes sont issues des valeurs crêtes **[34]** (supérieures, inférieures ou crêtes à crêtes) du signal temporel mesuré. Les plus utilisés sont le facteur crête et le facteur K.
Le facteur de crête (FC) défini comme étant le rapport entre la valeur crête (VC) d'un signal (en valeur absolue) et sa valeur efficace

$$FC=\frac{Vcc_{crete}}{V_{efficace}}=\frac{sup|x_i|}{RMS} \quad \text{(II.11)}$$

Le facteur K défini comme étant le produit entre la valeur crête et la valeur efficace.

$$K=V_{CC_{crete}}.V_{efficace} \quad \text{(II.12)}$$

Par comparaison avec la valeur efficace, le facteur crête **[35]** permet une détection plus précoce du défaut, qui se produit par des chocs liés par exemple au contact de surfaces dégradées. En effet, lorsque le roulement est sans défaut, le rapport entre la valeur crête et la valeur efficace reste sensiblement constant. La valeur du facteur crête est alors comprise entre 3 et 6.

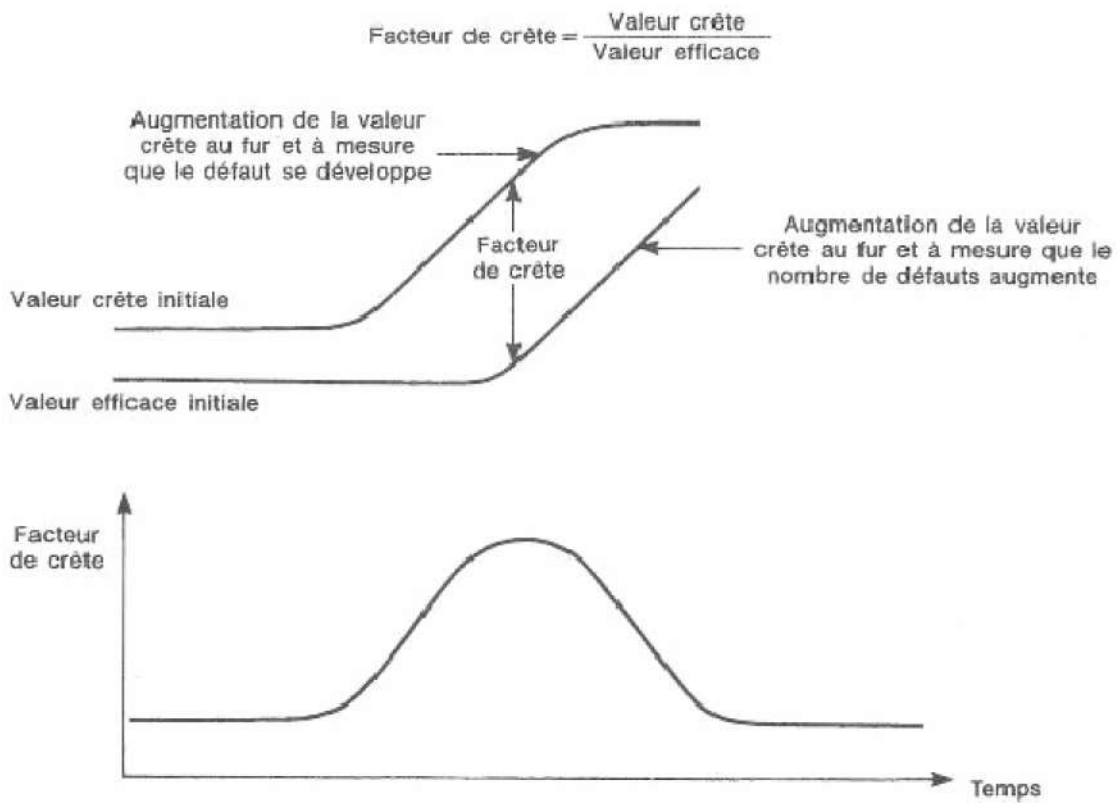



**Figure II.14**.Evolution du facteur de crête en fonction d'un défaut écaillage sur un roulement **[36].**

Quand une dégradation se développe, la valeur crête croît sensiblement, tandis que la valeur efficace reste sensiblement constante, la valeur du facteur crête devient alors supérieure à 6. Au fur et à mesure de la détérioration du roulement, la valeur crête augmentera jusqu'à atteindre une valeur limite, alors que la valeur efficace continue rade croître sous l'effet des impacts générés sous le passage des éléments roulants sur les défauts de piste (figure II.14). Cet indicateur est sensible à la taille des défauts dans les roulements **[37].**

### II.11.3.Le Kurtosis

Le Kurtosis est un indicateur statistique permettant de détecter l'apparition deschocs et de suivre l'évolution des défauts induisant des forces impulsion elles périodiques. Il permet la détection précoce d'un défaut de roulement. Il correspond au moment d'ordre 4 normé de la distribution statistique du signal. Il est défini comme suit :

$$Kurtosis=\frac{M_4}{M_2^2}=\frac{\frac{1}{n}\sum_{i=1}^{n}(x_i-\overline{x})^4}{\left[\frac{1}{n}\sum_{i=1}^{n}(x_i-\overline{x})^2\right]^2} \quad \text{(II.13)}$$

Où$M_4$,$M_2$sont les moments statistiques d'ordre 4 et d'ordre 2, respectivement.

$\bar{x}$est la valeur moyenne de$\{x_i\}$,$\bar{x} = \frac{1}{n}\sum_{i=1}^{n} x_i$(II.14)

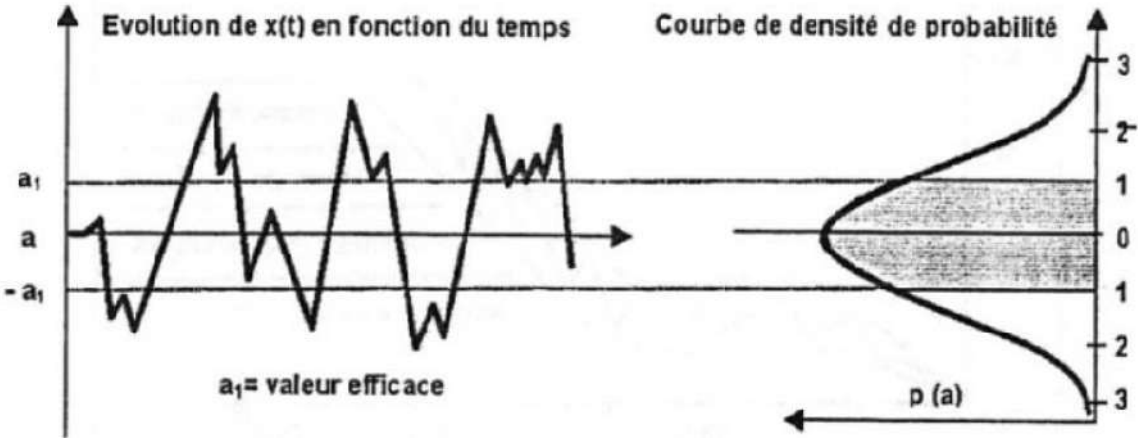



**Figure II.15**. Représentation schématique du Kurtosis.

Le Kurtosis doit cependant être utilisé avec beaucoup de précaution, car il est très sensible aux chocs [38], ce qui oblige un emploi du Kurtosis dans un environnement peu complexe afin de ne pas commettre d'erreurs de diagnostic.

### II.12.Fréquences caractéristiques des défauts de roulement

Les logiciels édités par les constructeurs de roulements permettent de déterminer rapidement et sans calcul les fréquences de défauts des roulements de la machine surveillée (figure II.16**)**

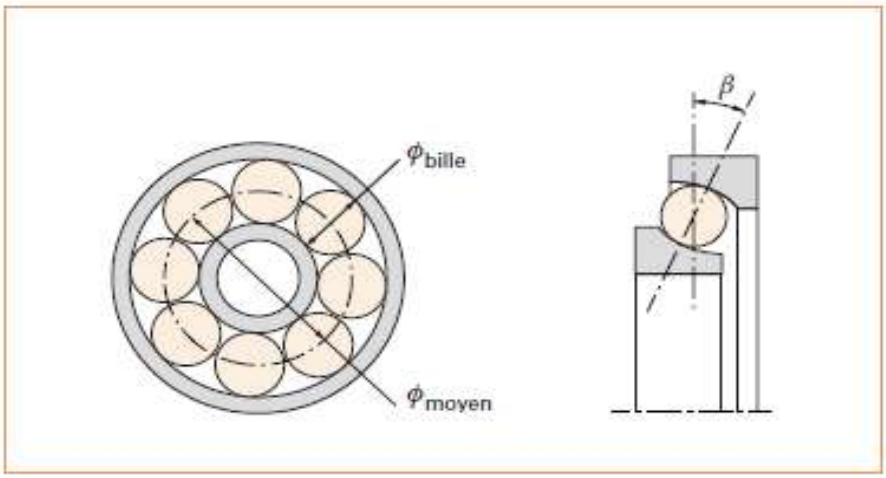



**Figure II.16**. Caractéristiques d'un roulement

On peut cependant les déterminer à l'aide des formules suivantes :

un défaut sur la piste externe se repère sur un spectre « enveloppe » à :

$$f_{ext} = \frac{n}{2} fr \left(1 - \frac{\emptyset_{bille}}{\emptyset_{moyen}} \cos\beta\right) \quad \text{(II.15)}$$

Un défaut sur la piste interne se repère sur un spectre « enveloppe » à :

$$f_{int} = \frac{n}{2} fr(1 - \frac{\square_{bille}}{\square_{moyen}} \cos\beta) \quad \text{(II.16)}$$

Un défaut sur une bille, un rouleau ou une aiguille (élément roulant) se repère sur un spectre « Enveloppe » à :

$$f_{bille} = \frac{\square_{bille}}{\square_{moyen}} fr \left|1 - (\frac{\square_{bille}}{\square_{moyen}} \cos\beta)^2\right| \quad \text{(II.17)}$$

n : nombre d'éléments roulants (billes, rouleaux, aiguilles),

$fr$:Fréquence de rotation de l'arbre,

$\square_{bille}$:Diamètre des éléments roulants

$\square_{moyen}$:Diamètre moyen d'évolution des éléments roulants,

$\beta$:Angle de contact.

### II.13.Niveaux globaux spécifiques aux roulements

Un roulement neuf et bien lubrifié n'émet, en théorie, aucun signal.

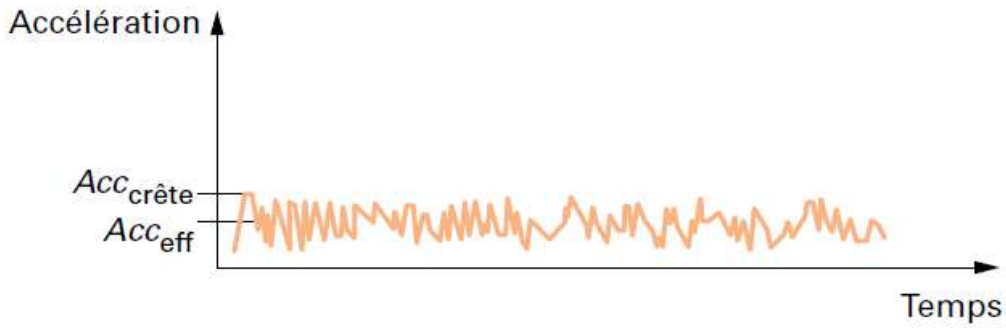



**Figure II.17** Roulement neuf

Lorsqu'un roulement se dégrade, cela commence très souvent par un trou(dittrou de pitting) à la surface de la piste interne.

Le signal émis peut être représenté par les deux schémas suivants :

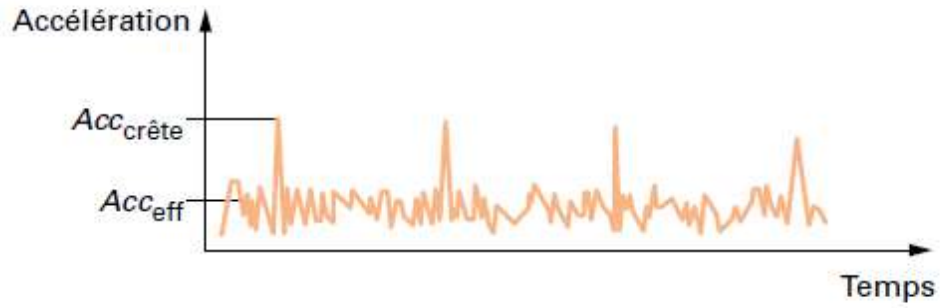



**Figure II.18** le trou de pitting apparait

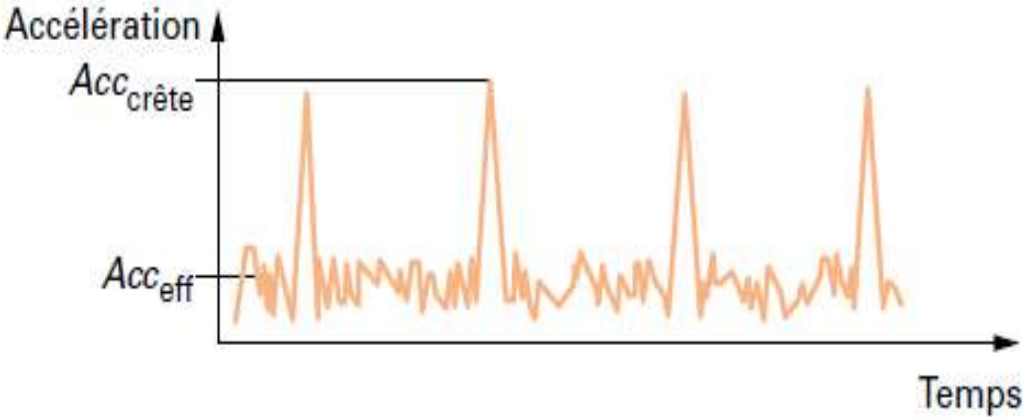



**Figure II.19**le trou de pitting se développe

En fin de vie, les trous de pitting se sont développés partout sur les pistes de roulement. Le signal émis ressemble alors à ces graphes :

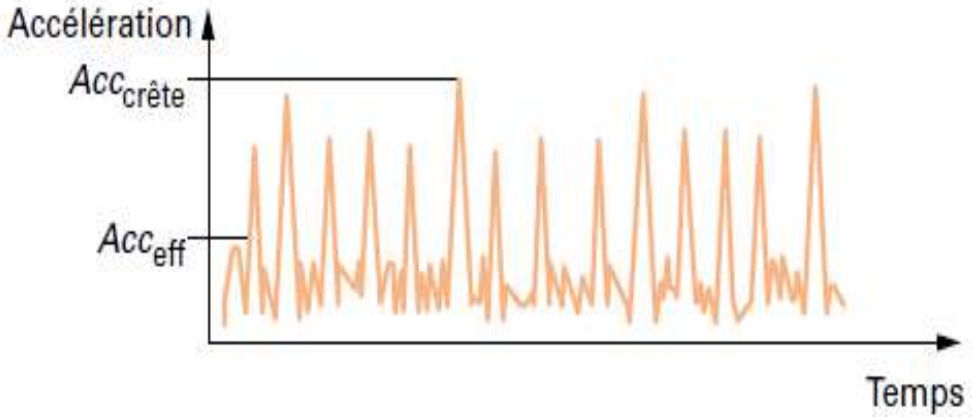



**Figure II.20**les trous de pitting se multiplient

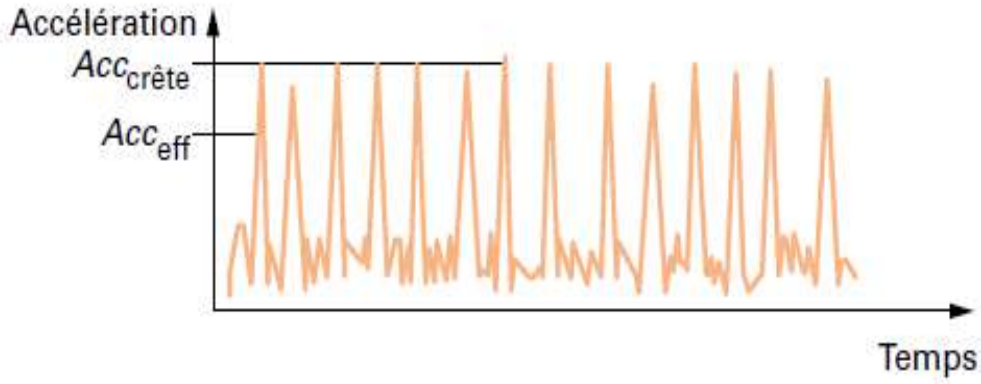



**Figure II.21**le roulement est hors service

## II.14.Conclusion

Le suivi de l'état de santé des machines tournantes s'appui sur l'analyse des vibrations. Cette analyse est la plus utilisé dans la maintenance à causes de la capacité des données vibratoires à donner la mesure la plus pertinente de l'état d'une machine en fonctionnement et à prédire de façon précoce le développement des défauts. Dans cette analyse on distingue les processus suivants: détection, localisation, identification et prédiction de l'évolutiondes défauts qui produisent les vibrations.

# Chapitre III  Modélisation et prévision neuronale des défauts de roulement

# Chapitre 3: modélisation et prévision neuronale du défaut de roulement

## III.1. Introduction

Le processus de diagnostic des défauts met l'accent sur l'isolation et l'identification des défauts quand ils se produisent. Ce processus permettant de tracer des graphes à partir des informations issues de la mesure et des indicateurs calculés. Traditionnellement, la reconnaissance des formes de ces graphes est faite manuellement avec des outils graphiques auxiliaires comme le spectre de puissance, le spectre déphase, le cepstre, le spectrogramme, le scalogramme en ondelettes. Cependant, la reconnaissance des formes manuelle exige une expérience particulière dans le domaine d'application du diagnostic et un personnel compétent et hautement formé. Plusieurs approches de diagnostic sont disponibles : approches statistiques, approches fiabilistes, approches de l'intelligence artificielle etapproches à base de modèles.

Les approches de l'intelligence artificielle populaires pour le diagnostic des machines sont les réseaux de neurones artificiels (RNA), des systèmes experts et de datamining. Pour former un modèle de diagnostic, les RNA sont basés sur des exemples(ou objets) de cas résolus et des entrées et des sorties connues.

Dans ce chapitre nous présentons les résultats préliminaires de la modélisation des défauts de roulement des machines tournante par les réseaux de neurones artificiels.

Ce chapitre est divisé en deux parties : la première partie concernela modélisation par les réseaux de neurones ou on a choisis le neurone optimal. Dans la deuxième partie on s'intéressera à la prévision.

Enfin on conclura ce chapitre en analysant et interprétant les différents résultats obtenus.

## III.2. Méthodologie de modélisation

### III.2.1. Collecte de s données

Dans cette étude, les données utilisées sont issues de la référence [39] Dans cette référence, plusieurs expériences réalisées pardes roulements à une rangée de billes de type SKF6206 montés

sur un banc d'essai de détection de défauts de roulement. Des défauts de différentes tailles de 8 $mm^2$ à 20 $mm^2$ réalisés par électroérosion sur la bague intérieure et sur la bague extérieure. Les essais sont effectués pour différentes vitesses de rotation et différentes charges radiales horizontales générées par un vérin hydraulique.

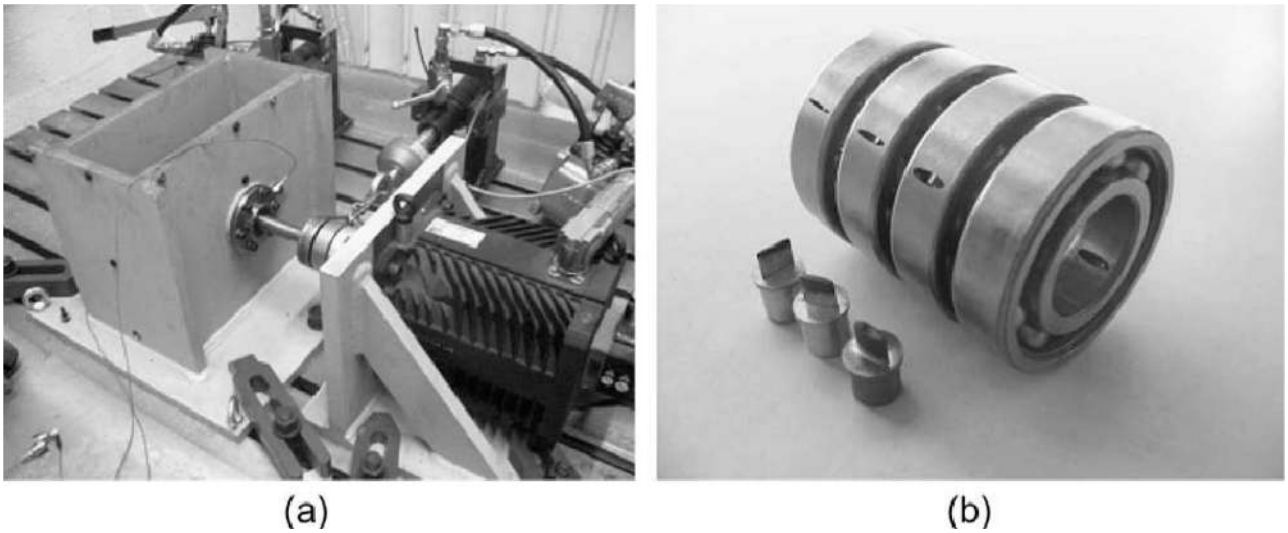



**Figure III.1.**Banc d'essai

L'acquisition des signaux vibratoires est effectuée par un système d'acquisition et par l'utilisation d'accéléromètres piézoélectriques.

L'ensemble de données accueillies sont résumés dans le tableau III.1 comme suit:

**Tableau III.1.** Données accueillies

| Signal | Kurtosis | FC | RMS | Classe (défauts) |
|---|---|---|---|---|
| 1 | 2,936 | 3.044 | 0.00375 | Bon |
| 2 | 3.021 | 3.241 | 0.00171 | Bon |
| …. | …. | ….. | …. | …. |
| 40 | 9.49 | 6,586 | 0,00598 | Dégradés |

La base de données obtenue est représentée par une matrice rectangulaire de 40ligne et 4colonnes

-Base de données d'entées réaliser par une matrice rectangulaire de dimension [40 ,3] ;

-Base de données de sorties réaliser par une matrice rectangulaire de dimension [40,1] ;

### III.2.2.Sélection des entrées et des sorties du modèle neuronale

D'une manière générale, lorsqu'on modélise un processus physique ou chimique, on détermine, par une analyse préalable du problème, les variables ont une influence sur le phénomène étudié

La sélection des entrées consiste à déterminer les variables pertinents par rapport à la grandeur à modélise. Elle vise deux points essentiels**[40]**

- Réduction de la dimension de l'espace de représentation des variables du modèle ;
- Elimination des entrées qui n'ont pas ou peu d'influence sur la sortie.

Il est important de mentionner que chaque ajout d'une variable encombre le modèle et entraine une multiplication des paramètres du réseau, raison pour laquelle, la représentation des entées doit contenir tous les facteurs par rapport à la grandeur à modélise, mais seulement ceux-ci. Dans notre cas, on a choisi comme ;

- **Entrées :**
  - **RMS** : indicateur qui mesure le continu énergétique dans un signale.
  - **Kurtosis :** indicateur statique permettant de détecter l'apparition des chocs et de suivre l'évolution des défauts induisant des forces impulsionnelles périodique.
  - **FC :** facteur de crête.
- **Sortie :**
  - **Classe de défaut** (Roulement bon, Roulement dégradé).

### III.2.3. Normalisation de la base de données partielle

La normalisation est une étape importante dans le processus de l'élaboration des données. Elle devient dans la plus part des cas, une exigence pour les matrices des inputs, du fait qu'on utilise souvent des fonctions de transfert bornées de type sigmoïdes dans les modélisations statiques.

Dans notre travail, on a utilisé la base de données qui est représentés par 4 colonnes (RMS, FC, Kurtosis, Classe de défaut) et 40 lignes. Les valeurs numériques ont été normalisées afin d'améliorer l'optimisation. La normalisation se fait par ligne (***mapminmax MATLAB version : 2013*** chaque paramètre des entrées et de sortie ($x_i$) est normalisé ($x_{in}$) par l'expression suivante:

$$x_{in} = \frac{2\{x_i - \min(x_i)\}}{\{\max(x_i) - \min(x_i)\}} - 1 \qquad \text{(III.1)}$$

### III.2.4.Mise en forme des données

Dans cette étape les données sont subdivisées en trois sous-ensembles:

- ✓ Un ensemble pour l'apprentissage (70%) : pour apprendre le réseau de neurone ;
- ✓ Un ensemble pour la phase de validation (15%) : pour connaitre l'arrêt de l'apprentissage ;
- ✓ Un ensemble pour le test (15%) : pour tester le modèle ;

Cette division c'est pour ne pas avoir le sou-apprentissage et le sur-apprentissage.

### III.2.5. Conception et optimisation

L'objectif principal des travaux décrits dans cette section a été réalisé pour trouver l'architecture du réseau de neurones optimale permettant de prédire la classe de défauts de roulement des machines tournantes.

La conception et l'optimisation du réseau a était réalisé en élaborant un programme en MATLAB 2013. Le nombre de neurones dans la couche cachée à été varié de1à10. Et on effectue dans chaque neurone 15 itérations.

On a trouvé comme fonction de transfert la fonction tangente sigmoïde « tansig » pour la couche cachée et la couche de sortie et comme algorithme d'apprentissage l'algorithme de Levenberg-Marquardt « trainlm ».

### III.3. Les étapes de l'exécution pour trouver le modèle mathématique (Annexe 1)

a) On a choisi « nnstart » comme chemin dans le matlab pour trouver un model mathématique
b) On choisi«neural network pattern recognition tool and classification».
c) on entre les entrées (input1) et la sortie (target).
d) Cette étape consiste avarie le nombre de neurone de 1 à10 et on a effectue dans chaque neurone 15 itération pour éviter le sur-apprentissage et le sous-apprentissage.
e) On a fait l'apprentissage et on enregistre toute les résultats obtenue afin de bien choisir le réseau optimal.

### III.3.1. Le choix de neurone optimal

Chaque neurone peut prendre en compte des profils spécifique de neurones d'entrée. Un nombre plus important permet donc de mieux coller aux données présentées mais diminue la capacité de généralisation du réseau. Il faut alors trouver le nombre adéquat de neurones cachés nécessaire pour obtenir une approximation satisfaisante .Alors dans ce stade on a modifié le nombre de neurone dans la couche cachée et on a effectué dans chaque neurone 15 itération et en choisir le neurone optimale en terme de pourcentage de classification, en enregistre la meilleure itération dans chaque neurone (exemple net2_3 : le deuxième neurone et la troisième itération)

**Tableau III.2**Le choix de neurone optimal

| Nombre de neurones dans la couche cachée | Nombre d'itération | La meilleure itération | Pourcentage % | Etat de classe |
|---|---|---|---|---|
| 1 | 15 | 2 | 80 | Bonne |
| 2 | 15 | 3 | 80 | Bonne |
| 3 | 15 | 5 | 95 | Parfaite |
| 4 | 15 | 7 | 100 | Parfaite |
| 5 | 15 | 8 | 100 | Parfaite |
| 6 | 15 | 14 | 55 | Mauvaise |
| 7 | 15 | 11 | 47.5 | Mauvaise |
| 8 | 15 | 6 | 80 | Bonne |
| 9 | 15 | 8 | 80 | Bonne |
| 10 | 15 | 5 | 80 | Bonne |

En remarque que il existe deux neurones optimaux qui sont : net4_7 et net 5_8.alors en fait la comparaison entre les deux neurones optimale.

#### III.3.1.1Structure Du RNSO Obtenu pour le 4$^{ème}$neurone de la couche cachée (net4_7)

La structure de base retenue est un perceptron multicouche à trois couches : une couche d'entrée, une couche cachée, une couche de sortie (Figure III.2). Le perceptron multicouche est une réseau de neurones non bouclé caractérisé par une structure bien particulière : ses neurones sont organisés en couches successives ou les information circulent dans un seul sens, de la couche d'entrée vers la couche de sortie.les neurones d'une même couche ne sont pas interconnectés.

### III.3.1.2 L'algorithme d'apprentissage et la fonction d'activation

L'algorithme d'apprentissage utilisé est Levenberg-Marquardt, avec l'option d'apprentissage atténué pour éviter le sur-apprentissage. La procédure commence par une fonction de transfert sigmoïde tangent hyperbolique (fonction tansig de MATLAB®) pour la couche cachée et aussi pour la couche de sortie

**Tableau III.3.**Structure des RNSO utilisés pour la modélisation des défauts.

| **Couche d'entrée** | **Couche cachée** | | **Couche de sortie** | | **Algorithme d'apprentissage** |
|---|---|---|---|---|---|
| Nombre de neurones | Nombre de neurones | Fonction d'activation | Nombre de neurones | Fonction d'activation | Levenberg-marquardt LM |
| 3 | 4 | Tangente sigmoïde « tansig » | 1 | Tangente sigmoïde « tansig | |

Ce tableau récapitule la structure de réseaux de neurone optimale obtenu avec 3neurones dans la couche d'entrée et 4neurones dans la couche cachée et un seul neurone dans la couche de sortie et pour les fonctions d'activation c'est Tangente sigmoïde « tansig » pour la couche cachée et la couche de sortie. On a testé des différentes architectures du réseau de neurones par la modification du nombre de neurones dans la couche cachée.

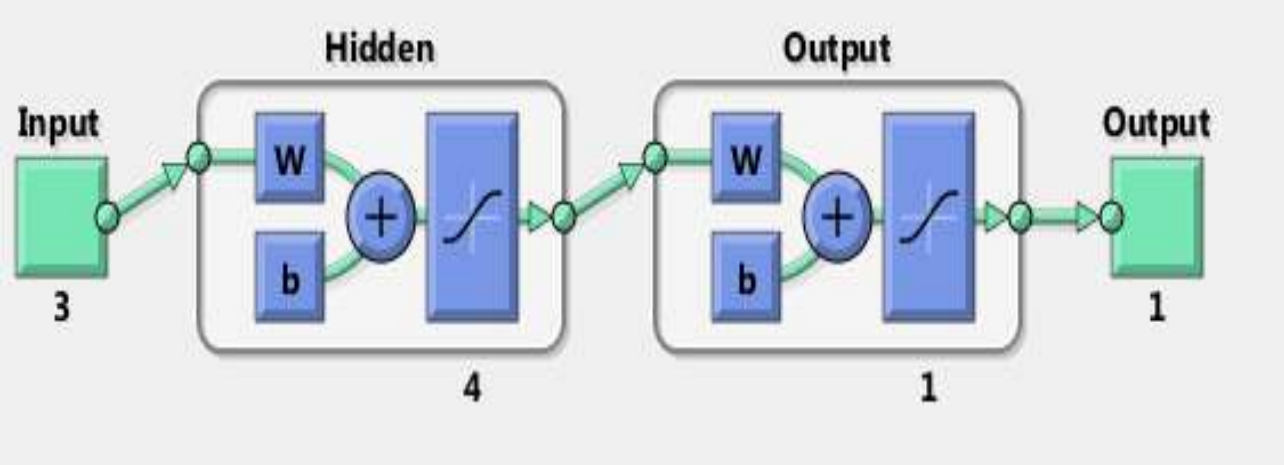



**Figure III.2.** Schéma simplifié de l'architecture du RNSO

La représentation schématique du perceptron pour notre réseau est donnée par la figure III.3.

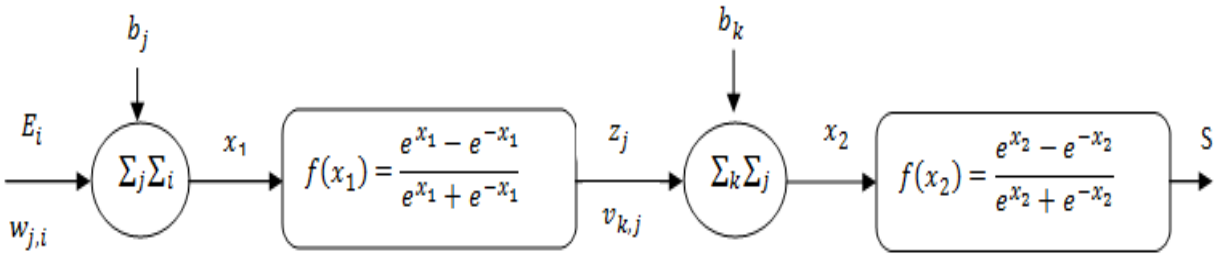



**Figure III.3.** Représentation schématique du RN*S* optimisé.

### III.3.1.3. Expressions mathématique des modèles neuronaux optimisés

À partir du RN*S* optimisé et qui est représenté sur la figure III.3 on peut exprimer l'assimilation des défauts par un modèle mathématique qui y incorpore toutes les entrées $E_i$ comme suit:

$$x_1 = \sum_{i=1}^{3} E_i w_{j,i} + b_j \quad \text{(III.2)}$$

i=1,2,3.

Les sorties $Z_j$ de la couche cachée:

$$z_j = f(x1) = f(\sum_{i=1}^{3} E_i w_{j,i} + b_j) \quad \text{(III.3)}$$

$j=1, 2, \dots, 4$

$$f(x_1) = \frac{e^{x_1} - e^{-x_1}}{e^{x_1} + e^{-x_1}} = z_j \quad \text{(III.4)}$$

$$z_j = \frac{e^{\sum_{i=1}^{3} E_i w_{j,i} + b_j} - e^{-\sum_{i=1}^{3} E_i w_{j,i} + b_j}}{e^{\sum_{i=1}^{3} E_i w_{j,i} + b_j} + e^{-\sum_{i=1}^{3} E_i w_{j,i} + b_j}} \quad \text{(III.5)}$$

$$x_2 = \sum_{j=1}^{4} z_j v_{k,j} + b_k \quad \text{(III.6)}$$

$$S = f(x_2) = \frac{e^{x_2} - e^{-x_2}}{e^{x_2} + e^{-x_2}} \quad \text{(III.7)}$$

La combinaison des équations (III.6) et(III.7) mène à la formule mathématique suivante qui décrit l'assimilation des défauts en prenant en compte toutes les entrées $E_i$ :

$$S = \frac{e^{\sum_{j=1}^{4} z_j v_{k,j} + b_k} - e^{-\sum_{j=1}^{4} z_j v_{k,j} + b_k}}{e^{\sum_{j=1}^{4} z_j v_{k,j} + b_k} + e^{-\sum_{j=1}^{4} z_j v_{k,j} + b_k}} \quad \text{(III.8)}$$

Ou$w_{j,i}$représente le poids synaptique de la connexion du neurone *i* de la couche d'entrée au neurone *j* de la couche cachée ;$v_{k,j}$représente le poids synaptique de la connexion du neurone *j* de la couche cachée au neurone de la couche de sortie ; $b_j$et $b_k$ représentent respectivement les biais du neurone *j* de la couche cachée et du neurone de lacouche de sortie. Les matrices des poids et biais, de RNS optimisés, sont donnés dans le tableau III.4

**Tableau III.4.**Poids et biais du RNS optimal

| **Connexions Couche d'entrée-Couche cachée** | | | | **Connexions Couche cachée-Couche de sortie** | |
|---|---|---|---|---|---|
| **Poids** | | | **Biais** | **Poids** | **Biais** |
| $w_{j,i}$ | | | $b_j$ | $v_{k,j}$ | $b_k$ |
| 1.036 | -0.46278 | -1.9566 | 0.44034 | -2.1027 | -0.79296 |
| -2.1254 | -0.28801 | -0.64332 | -0.10505 | 0.83411 | |
| 1.2337 | 0.77788 | 1.0328 | -1.6642 | 1.9061 | |
| 1.6466 | 1.4455 | 0.11481 | -3.5351 | 2.5883 | |

### III.3.1.4 Performance du réseau de neurone en termes de pourcentage de classification

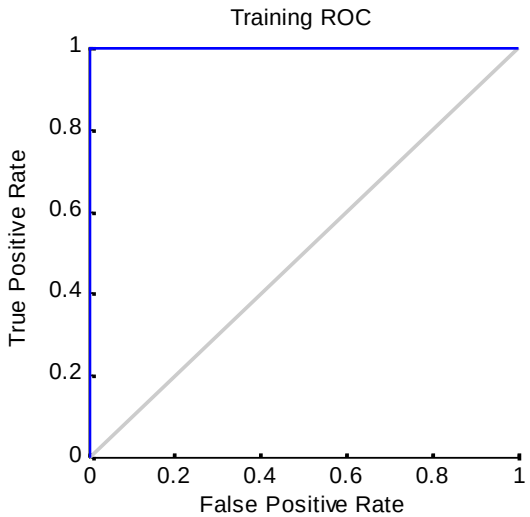



**Figure III.4.** Performance du réseau de neurone en termes de pourcentage de classification pour la base d'apprentissage

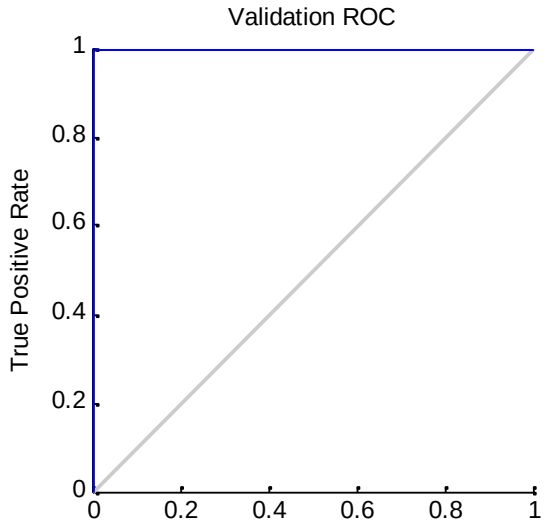



**Figure III.5** Performance du réseau de neurone en termes de pourcentage de classification pour la base de validation

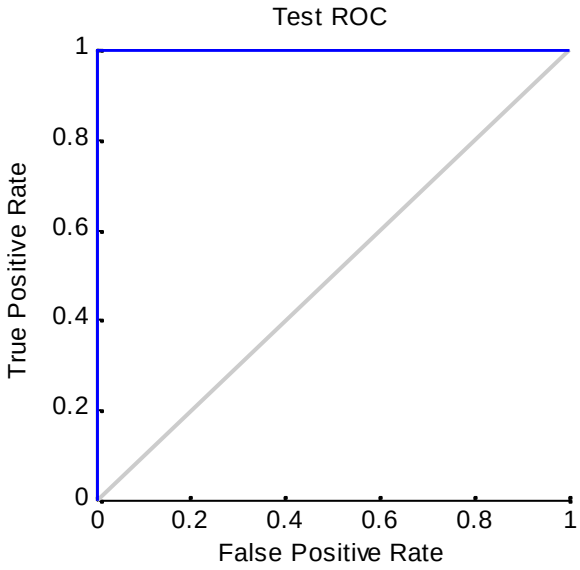



**Figure III.6**Performance du réseau de neurone en termes de pourcentage de classification pour la base de teste

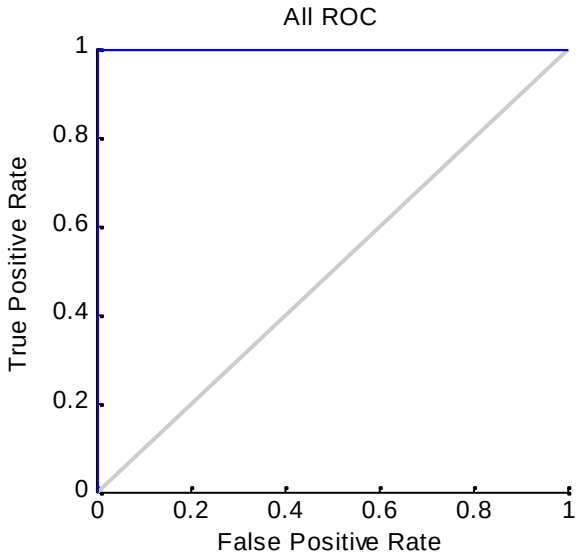
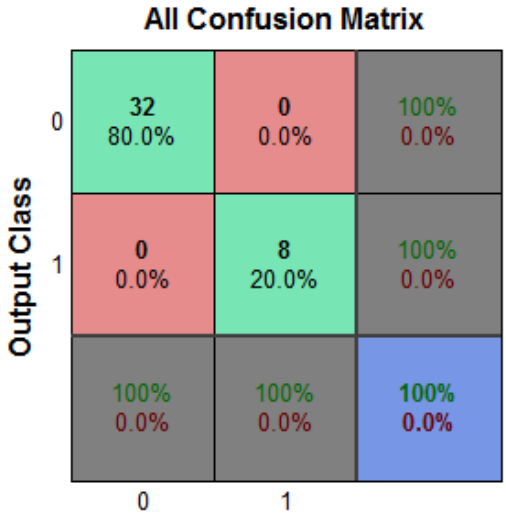



**Figure III.7**Performance du réseau de neurone en termes de pourcentage de classification pour toute la base

Le pourcentage de classification est parfait pour la base d'apprentissage, de validation, teste, et pour toute la base car d'une part le classement se situe linéairement sur la droite des coordonnes et des absices et d'autre part la base des données est très réduite avec 40 cas.

### III.3.1.5 Evaluation des performances du modèle par la matrice de confusion pour le 4ème neurone

**Tableau III.5.**Matrice de confusion




Les cases en vert signifie qu'il y a 32 cas qui sont dégradés(VP) et 8 casqui sont bonnes (VN, donc :

Par définitions, le taux de classification TC : TC= (VP+VN)/(VP+FP+FN+VN).

Le taux de classification=$\frac{VN+VP}{le\ nombre\ total\ des\ cas}$=$\frac{32+8}{40}$=1=100% donc d'après la matrice de confusion en constate que la classification est parfaite.

### III.4. Validation des résultats obtenus par RNA avec les valeurs expérimentale

Le tableau III.6 présente la validation des valeurs prédites par réseau de neurone avec les valeurs expérimentale pour toute la série de données. Nous pouvons remarquer d'une part que les valeurs prédites par la méthode neuronale coïncidente avec les valeurs expérimentales

MSE: l'erreur quadratique moyenne (means quared error)

SSE: l'erreur de la somme quadratique (sums quared error)

**Tableau III.6.**Validation des résultats obtenus par RNA avec les valeurs expérimentale

| Sortie expérimentales SE | Sortie calculée par RNA SRNA | SE – SRNA | MSE | SSE |
|---|---|---|---|---|
| 1 | 0.7416 | 0.2584 | 0.0219 | 0.8764 |
| 1 | 0.9255 | 0.0745 | | |
| 1 | 0.6754 | 0.3246 | | |
| 1 | 0.9831 | 0.0169 | | |
| 1 | 0.6697 | 0.3303 | | |
| 1 | 0.8234 | 0.1766 | | |
| 1 | 0.5897 | 0.4103 | | |
| 1 | 0.8984 | 0.1066 | | |
| 0 | 0.0020 | -0.0020 | | |
| 0 | 0 | 0 | | |
| 0 | 0.4023 | -0.4023 | | |
| 0 | 0 | 0 | | |
| 0 | 0,0032 | -0.0032 | | |
| 0 | 0.0004 | -0.0004 | | |
| 0 | 0 | 0 | | |
| 0 | 0.4664 | -0.4664 | | |
| 0 | 0.0001 | -0.0001 | | |
| 0 | 0.001 | 0.00 | | |
| 0 | 0 | 0 | | |
| 0 | 0.0057 | -0.0057 | | |

| | | | | |
|---|---|---|---|---|
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0.001 | -0.001 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |

### III.4.1 Prévision d'une classe

#### III.4.1.1 Test du modèle

On utilise la simulation sur MATLAB pour la prévision des classes comme suivant :

Y1=Sim (net4_7, [3;3;0.003])=0.8799

Y2=Sim (net4_7, [4;5;0.1]) =3.1995$e^{-06}$

**Tableau III.7.**prévision des clases

| Indicateur | Kurtosis | RMS | FC | Prédiction de la classe | Classe réelle |
|---|---|---|---|---|---|
| **Cas 1** | **3** | **0.003** | **3** | **0.8799** | **Bon: 1** |
| **Cas 2** | **4** | **0.1** | **5** | **3.1995e-06** | **Dégradé: 0** |

D'après l'utilisation du modèle sur les deux cas cités dans le tableau III.7, on constate que le modèle à estimé parfaitement la classe des deux cas prédites.

### III.4.1.2Structure Du RNSO Obtenu pour le 5ème neurone (net 5_8)

La structure de base retenue est un perceptron multicouche à trois couches : une couche d'entrée, une couche cachée, une couche de sortie (Figure III.8).

**Tableau III.8.**Structure des RNSO utilisés pour la modélisation des défauts.

| **Couche d'entrée** | **Couche cachée** | | **Couche de sortie** | | **Algorithme d'apprentissage** |
|---|---|---|---|---|---|
| Nombre de neurones | Nombre de neurones | Fonction d'activation | Nombre de neurones | Fonction d'activation | Levenberg-marquardt LM |
| 3 | 5 | Tangente sigmoïde « tansig » | 1 | Tangente sigmoïde « tansig | |

Ce tableau récapitule la structure de réseaux de neurone optimale obtenu avec 3neurones dans la couche d'entrée et 5 neurones dans la couche cachée et un seul neurone dans la couche de sortie et pour les fonctions d'activation c'est Tangente sigmoïde« tansig » pour la couche cachée et la couche de sortie.

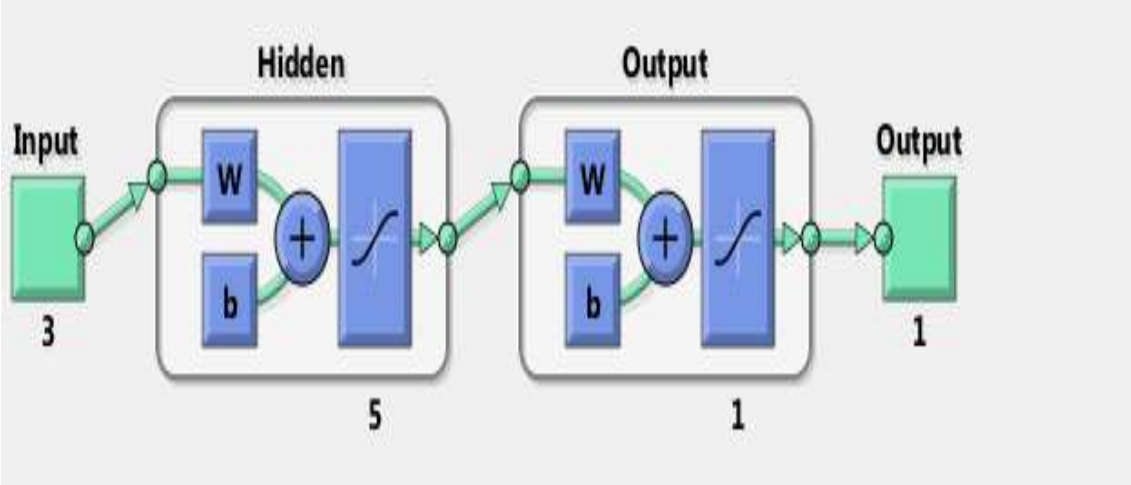



**Figure III.8.** Schéma simplifié de l'architecture du RNSO

La représentation schématique du perceptron pour notre réseau est donnée par la figure III.9.

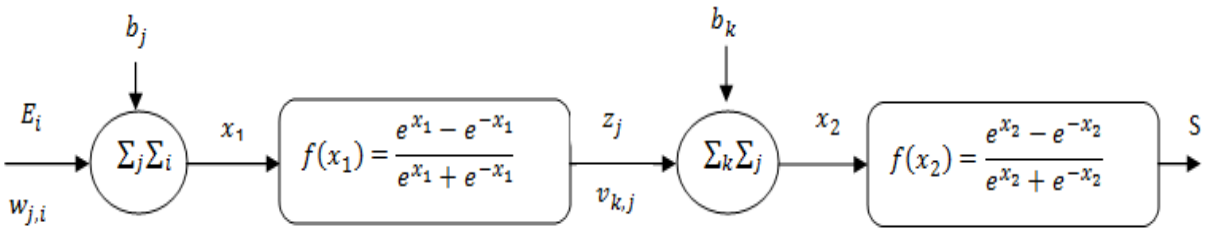



**Figure III.9.** Représentation schématique du RNS optimisé(net 5_8).

### III.4.1.3 Expressions mathématique des modèles neuronaux optimisés

$$x_1 = \sum_{i=1}^{3} E_i w_{j,i} + b_j \quad \text{(III.9)}$$

i=1, 2,3.

Les sorties $Z_j$de la couche cachée:

$$z_j = f(x1) = f(\sum_{i=1}^{3} E_i w_{j,i} + b_j) \quad \text{(III.10)}$$

$j=1, 2, \dots, 5$

$$f(x_1) = \frac{e^{x_1} - e^{-x_1}}{e^{x_1} + e^{-x_1}} = z_j \quad \text{(III.11)}$$

$$z_j = \frac{e^{\sum_{i=1}^{3} E_i w_{j,i} + b_j} - e^{-\sum_{i=1}^{3} E_i w_{j,i} + b_j}}{e^{\sum_{i=1}^{3} E_i w_{j,i} + b_j} + e^{-\sum_{i=1}^{3} E_i w_{j,i} + b_j}} \quad \text{(III.12)}$$

$$x_2 = \sum_{j=1}^{5} z_j v_{k,j} + b_k \quad \text{(III.13)}$$

$$S = f(x_2) = \frac{e^{x_2} - e^{-x_2}}{e^{x_2} + e^{-x_2}} \quad \text{(III.14)}$$

La combinaison des équations (III.13) et(III.14) mène à la formule mathématique suivante qui décrit l'assimilation des défauts en prenant en compte toutes les entrées $E_i$ :

$$S = \frac{e^{\sum_{j=1}^{5} z_j v_{k,j} + b_k} - e^{-\sum_{j=1}^{5} z_j v_{k,j} + b_k}}{e^{\sum_{j=1}^{5} z_j v_{k,j} + b_k} + e^{-\sum_{j=1}^{5} z_j v_{k,j} + b_k}} \quad \text{(III.15)}$$

Ou

$w_{j,i}$ Représente le poids synaptique de la connexion du neurone *i*de la couche d'entrée au neurone *j* de la couche cachée;

$v_{k,j}$: Représente le poids synaptique de la connexion du neurone *j* de la couche cachée au neurone de la couche de sortie;

$b_j$et$b_k$ : représentent respectivement les biais du neurone *j*de la couche cachée et du neurone de lacouche de sortie.

Les matrices des poids et biais, de RNS optimisés, sont donnés dans le tableauIII.9

**Tableau III.9.**Poids et biais du RNS optimal

| **Connexions Couche d'entrée-Couche cachée** | | | | **Connexions Couche cachée-Couche de sortie** | |
|---|---|---|---|---|---|
| **Poids** | | | **Biais** | **Poids** | **Biais** |
| $w_{j,i}$ | | | $b_j$ | $v_{k,j}$ | $b_k$ |
| -1.5492 | -0.18935 | -1.802 | 2.427 | 0.5506 | -0.024447 |
| -2.3368 | -0.44225 | -0.3599 | 1.0866 | 1.0553 | |
| -1.9079 | 2.6893 | 1.0036 | 0.87291 | -3.0149 | |
| 2.2155 | 0.78068 | -0.76414 | 0.9514 | -0.25178 | |
| 0.36341 | 2.8076 | 0.76323 | 3.2132 | -3.4339 | |

### III.4.1.4 Performance du réseau de neurone en termes de pourcentage de classification

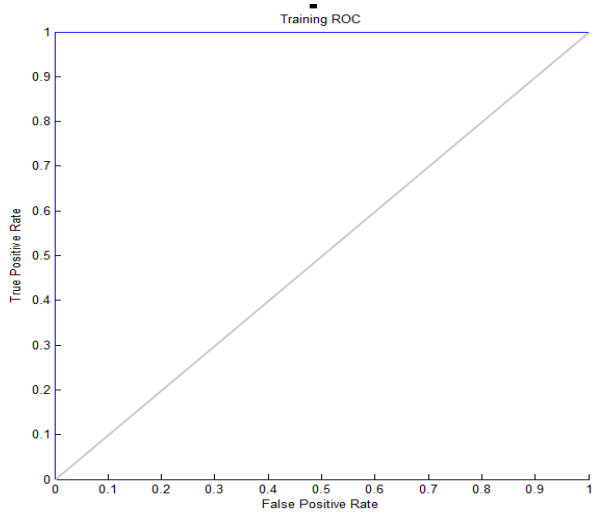



**Figure III.10.** Performance du réseau de neurone en termes de pourcentage de classification pour la base d'apprentissage

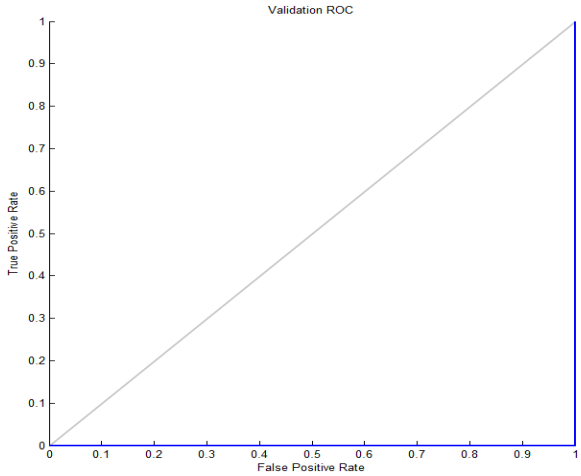



**Figure III.11**Performance du réseau de neurone en termes de pourcentage de classification pour la base de validation

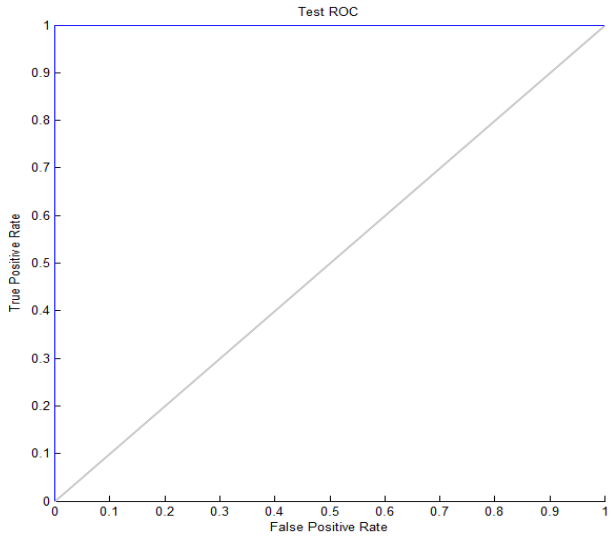



**Figure III.12**Performance du réseau de neurone en termes de pourcentage de classification pour la base de teste

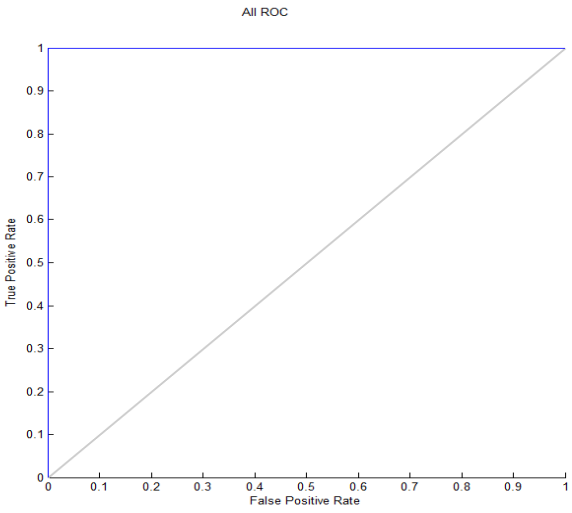



**Figure III.13**Performance du réseau de neurone en termes de pourcentage de classification pour toute la base

### III.4.1.5 Interprétation des graphes

Le pourcentage de classification est parfait pour la base d'apprentissage et la base de teste car le classement se situe linéairement sur la droite des coordonnes et des absices mais pour la base de validation en remarque que le classement se situe au dessous la droite c-à-d le classement est incorrecte alors les performances du modèle neuronale ne sont pas satisfaisante, il faudra, soit modifier l'architecteur du réseau, soit modifier la base d'apprentissage.

### III.4.1.6 Validation des résultats obtenus par RNA avec les valeurs expérimentale

Le tableau III.10 présente la validation des valeurs prédites par réseau de neurone avec les valeurs expérimentale pour toute la série de données.

**Tableau III.10.**Validation des résultats obtenus par RNA avec les valeurs expérimentale

| Sortie expérimentales SE | Sortie calculée par RNA SRNA | SE – SRNA | MSE | SSE |
|---|---|---|---|---|
| 1 | 0,9346 | 0.0654 | 0.0127 | 0.5100 |
| 1 | 0,9993 | 0.0007 | | |
| 1 | 0,8862 | 0.1138 | | |
| 1 | 0,9999 | 0.0001 | | |
| 1 | 0,8361 | 0.1639 | | |
| 1 | 0,9871 | 0.0129 | | |
| 1 | 0,5605 | 0.4395 | | |
| 1 | 0,9951 | 0.0049 | | |
| 0 | 0,0001 | -0.0001 | | |
| 0 | 0 | 0 | | |
| 0 | 0,1619 | -0.1619 | | |
| 0 | 0 | 0 | | |
| 0 | 0,0001 | -0.0001 | | |
| 0 | 0 | 0 | | |
| 0 | 0,4963 | -0.4963 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0,0001 | -0.0001 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |

| | | | | |
|---|---|---|---|---|
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |
| 0 | 0 | 0 | | |

Le tableau III.11récapitule l'erreur Mean Squared Error(MSE),et l'erreur Sum Squared Error (SSE)

## III.5.Conclusion

La méthode utilisée pour la prédiction des défauts de roulement s'avère pertinente et robuste pour déterminer la présence ou l'absence des défauts de roulements. Les résultats obtenus ont montré l'importance des attributs le Kurtosis, Facteur de crête (FC) et RMS dans la détection de ces défauts. Le taux de classification obtenu montre que la modélisation et parfaite.

Le réseau optimal obtenu dans cette étude c'est un réseau avec une architecteur {3-4-1} :3 neurone dans la couche d'entrée et 4 neurones dans la couche cachée et un seule neurone dans la couche de sortie.

# Conclusion générale

# Conclusion générale et perspective

Ce travail nous a permis de mettre en œuvre une méthode de diagnostic des défauts des machines tournantes par approche neuronale afin d'éviter les techniques classiques de détection de défauts reposant sur le traitement de signal. Ces dernières sont très souvent assez fastidieuses et complexes à mettre en place.

Notre première contribution a porté sur l'utilisation des réseaux de neurones artificiels (de types perceptron multicouches) pour exprimer l'assimilation des défauts par un modèle mathématique qui y incorpore toutes les entrées.

Le développement de cette approche après élaboration d'un programme sur MATLAB a été fondé sur deux étapes. En premier, niveau conceptuel qui comportera la préparation de la base de données et l'optimisation pour trouver l'architecture du réseau de neurones statique optimal(RNSO). En second, niveau de mise en œuvre de l'architecture obtenue, dans le but et le test de généralisation du réseau de neurone optimisé.

Le RNSO obtenue durant cette contribution comporte :

3 neurones dans couche d'entrées, 4 neurones dans la couche cachées, et un seul neurone dans la couche de sortie {3-[4]-1}, avec une MSE=0.0219 et SSE=0.8764.

Notre deuxième contribution a porté sur l'étude de prévision d'une classe a fin de tester le modèle neuronale.les résultats obtenus lors de cette contribution montre que les réseaux de neurones sont des outils parfaitement fiables et performants pour la prévision d'une classe (bon, dégradées).

Les conclusions fondamentales à retenir lors de cette étude, peuvent être récapitulées comme suit :

- Les réseaux de neurones fonctionnent comme une boite noire et les paramètres du réseau (poids et biais) n'ont pas de signification physique ;
- La modélisation par réseau de neurones est une méthode qui est basée seulement sur des données expérimentale et/ou semi expérimentale, donc la qualité et la quantité des données décident de l'exactitude et la robustesse du modèle ;
- La méthode neuronale choisie pour la prédiction des défauts de roulement s'avère pertinente et robuste pour la prédiction des défauts des pièces mécaniques des machines tournantes.

- L’application des réseaux neuronaux ne développe pas directement la théorie de description du système, mais rend faisable la modélisation et la simulation ;

En perspectives, touts en estimant avoir atteint notre objectif tracé pour cette étude, il serait intéressant de :

- Elargir la base de données a fin de tester l’extrapolation sur d’autre états de roulement.
- Etude de diagnostic des défauts combiné par exemple roulement+engrenage, l’utilisation des algorithmes génétique peut aussi apporter des améliorations.
- Tester d’autre approche telle que celles associant la logique floue et les réseaux de neurones appelées Neuro-floue.

# Références bibliographiques

**REFERENCE BIBLIOGRAPHIQUE**

**[1]** Introduction l'intelligence artificielle :Support de Cours IA-2001 Jean-Daniel Zucker LIP6

**[2]** Modélisation du neurone biologique en neurone formel, **W.McCulloch et W.Pitts**, 1943

**[3]** Règle de Hebb, D.Hebb,1949

**[4]** Mise en avant des limites du Perceptron - Abandon des recherches, M.Minsky et S.Papert,1969

**[5]** Modèle de Hopfield - Théorie du fonctionnement et des possibilités des réseaux de neurones, **J.J.Hopfield**, 1982

**[6]** Réseaux de neurones et intelligence Artificielle

**[7]** Hichem marmouz'' mémoire sur la modélisation neuronale de l'activité antibactérienne des molécules en utilisant les descripteurs QSAR. 2009-2010

**[8]** Chapitre 3 Les réseaux de neurones PDF

**[9]** Introduction aux réseaux de neurones cours_RN_2006.pdf

**[10]** Les réseaux de neurones. Vincent Lemaire.pdf.17.05.2012

**[11]** ''Sarah rezazi'' modélisation de la préduction de l'effet thérepeutique a partir de la structure moléculaire. 2010-2011

**[12]** https://sites.google.com/site/tpeiag5lnbahmv/.23.5.2012

**[13]** http://fr.wikipedia.org/wiki/Neurone_formel

**[14]** https://sites.google.com/site/tpeiag5lnbahmv/.23.5.2012

**[15**] Compte rendu de réseaux de neurones. Dumon antoine et gourio-jewell pierre-guillaume

**[16]** Introduction aux Réseaux de Neurones Artificiels Feed Forward. par Alp Mestan (Site perso de Alp) (Blog).PDF

**[17]** Réseaux de Neurones Artificiels. Manuel Clergue. Introduction. Définition. Contexte Scientifique. Historique. Fondements Biologiques.ppt

**[18]** Dangers_ risques _pesticides Final .pdf.p6

**[19]'**'AMI ET MELZI'' thèse de master 'Prédiction neuronale de l'effet toxicologique des fongicides.'', UNIVERSITE Dr. YAHIA FARES DE MEDEA (juin 2011), Algérie

**[20]** Réseaux de neurones artificiels. TIPE 2009.pdf.21.5.2012

**[21]** R.K.Mobley. « An Introduction to Predictive Maintenance », Second Edition, Elsevier Science (USA), p1-177, 2002.

**[22]** J.DEMANS. « La Surveillance Vibration- Maintenance Prédictive de l'outil de

Production», Achats et Entretien, N° 382-02-86, p25-36, 1986.

**[23]** C.BRENEUR. «Eléments de Maintenance Préventive des Machines Tournantes Dans le Cas des Défauts Combinés D'engrenages et Roulements». Thèse de Doctorat, Institut National des Sciences Appliquées de LYON, 2002.

**[24] PING Chen**: Bearing condition monitoring and fault diagnosis, these doctorat 2000, The University of Calgary. Canada.

**[25] BOULANGER Alain** ; Surveillance des machines tournante par analyse vibratoire, édition DUNOD 2002.

**[26] RUBINI R.** And U. Meneghetti 2001: Aapplication of the envelope and wavelet transform analyses for the diagnosis of incipient faults in ball bearings, Mechanical Systems and Signal Processing (2001) Vol 15(2), 287/302

**[27] Z.K. Penga**, F.L. Chua, et Peter W. Tseb 2003: Detection of the rubbing-caused impacts for rotor–stator fault diagnosis using reassigned scalogram'' Mechanical Systems and Signal Processing 19 (2005) pp 391-409.

**[28] ABDULLAH M.** Al-Ghamd, et David Mba ''A comparative experimental study on the use of acoustic emission and vibration analysis for bearing defect identification and estimation of defect size '' Mechanical Systems and Signal Processing .26/01/2005.

**[29] BIGRET.R** & FERON J.-L, Diagnostic Maintenance Disponibilité des Machines Tournantes, édition MASSON 1995.

**[30].** Tandon N, Choudury A. A review of vibration and acoustic measurcmcnt methods

for the detection of defects in rolling element bearings. Tribology International. 1999, 32. 205, 469-480.

**[31].** Ericsson E, Grip N, Johansson E, Persson L.E, Sjoberg R, Stronberg J.O. Towards automatic detection of local bearing defects in rotating machines. Mechanical systems and signal processing. 2005, 19, 509-535.

**[32].** Jardine, D.Lin,D.Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance. Mechanical systems and signal processing. 2006, 20, 1483–1510.

**[33]** Boumahdi M, Rechak S. Surveillance et diagnostic des défauts de roulement par analyse vibratoire. JM'EMP6, 6ème Journées de mécanique. 15-16 Avril 2008,
Bordj El Bahri, Alger.

**[34]** Boulenger A, Pachaud C. Diagnostic vibratoire en maintenance préventive. Dunod, 1998.

**[35]** Pachaud C. Crest factor and kurtosis contributions to identify defects inducing periodical impulsive forces. Mechanical Systems and Signal Processing. 1997,
11, 6, 903-916.

**[36]** Cousinard, O. Contribution à l'étude et au développement d'un système intégré de suivi de l'endommagement des composants mécaniques sur machines tournantes:
Application au développement et au choix des outils d'analyse et de
Mesure vibratoire. Thèse de doctorat de l'Université de Reims. 2002.

**[37]** Tandon, N. A comparison of sorne vibration parameters for the condition monitoring of rolling element bearings. Measurement. 1994, 12, 285-289.

**[38]** Drone J.P, Rasolofondraibe L, Bolaers F, Pavan A,. High-resolution methods in vibratory analysis: application to ball bearing monitoring and production machine.
IJSS. 2001, 38, 4293-4313.

**[36]** Cousinard, O. Contribution à l'étude et au développement d'un système intégré de suivi de l'endommagement des composants mécaniques sur machines tournantes:
Application au développement et au choix des outils d'analyse et de
Mesure vibratoire. Thèse de doctorat de l'Université de Reims. 2002.

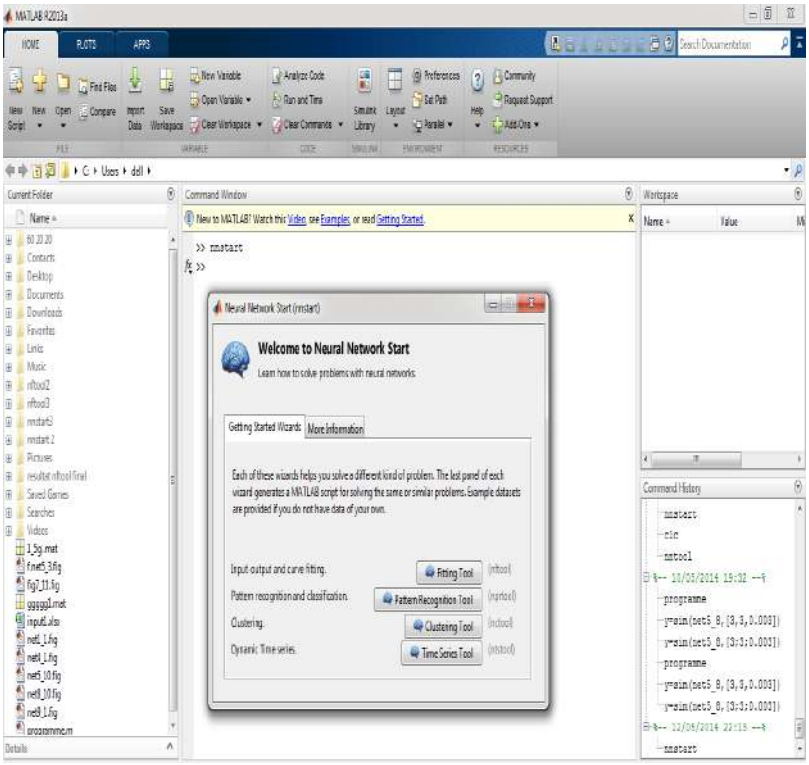
**[39]** M .Boumahdi, J-P Dron, S Rechak et O Cousinard, Application des arbres de décision au diagnostic des roulements, CAM2009, Biskra Algérie, Congrès Algérien de Mécanique, Novembre 2009. **Usure**

**[40]** [Hinton(1989)]

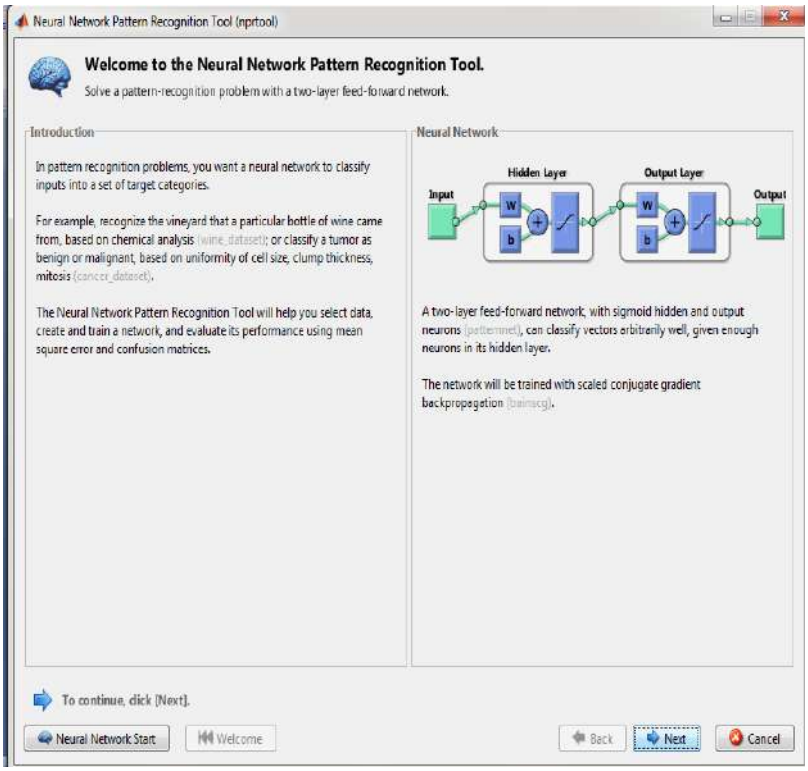
# Annexes

## Annexe 1: Les étapes de construction d'un modèle RA par la fonction nnstart

**Etape 1:** Exécuter la fonction nnstart



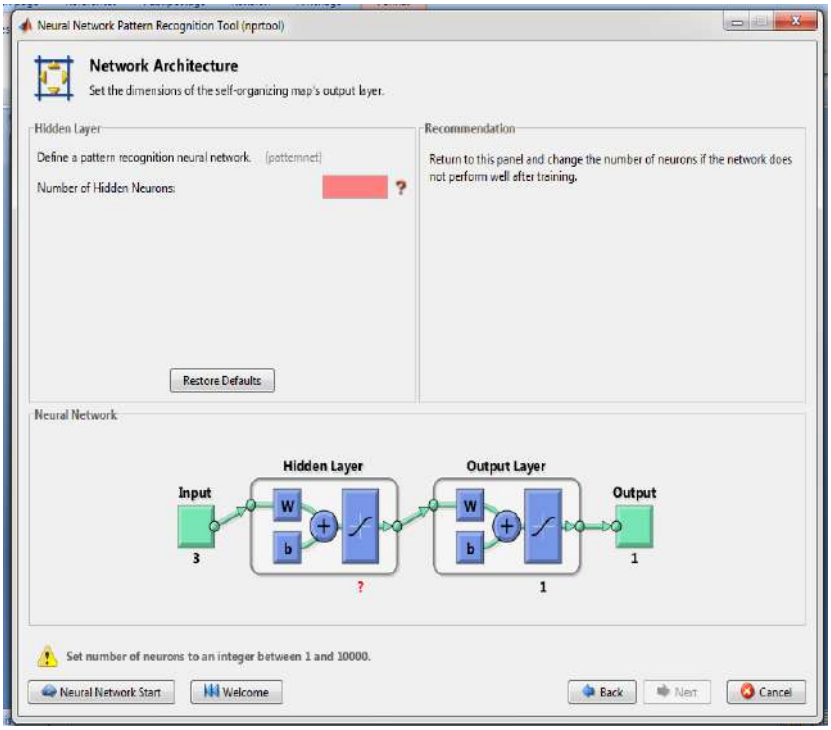

**Etape 2:** Cliquer sur Pattern Recognition tool



**Etape 3:** Charger la base de données




**Etape 4:** Choisir le nombre de couches cachés



**Etape 5:**Cliquer sur le bouton TRAIN pour commencer l'apprentissage

